

UNIVERSIDADE FEDERAL DO PARANÁ

JOÃO MARCOS CARVALHO

MATRIZES DE TRANSIÇÃO COMO FERRAMENTA DE ANÁLISE E PREVISÃO DA
QUALIDADE DA ÁGUA EM RESERVATÓRIOS - ESTUDO DE CASO:
RESERVATÓRIO DA UHE JURUMIRIM.

CURITIBA

2021

JOÃO MARCOS CARVALHO

MATRIZES DE TRANSIÇÃO COMO FERRAMENTA DE ANÁLISE E PREVISÃO DA
QUALIDADE DA ÁGUA EM RESERVATÓRIOS - ESTUDO DE CASO:
RESERVATÓRIO DA UHE JURUMIRIM.

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Recursos Hídricos e Ambiental, Setor de Tecnologia da Universidade Federal do Paraná, como requisito para a obtenção do grau de Mestre.

Orientador: Prof. Dr. Tobias Bleninger

CURITIBA

2021

Catálogo na Fonte: Sistema de Bibliotecas, UFPR
Biblioteca de Ciência e Tecnologia

C331m

Carvalho, João Marcos

Matrizes de transição como ferramenta de análise e previsão da qualidade da água em reservatórios - estudo de caso: reservatório da UHE Jurumirim [recurso eletrônico] / João Marcos Carvalho. – Curitiba, 2021.

Dissertação - Universidade Federal do Paraná, Setor de Tecnologia, Programa de Pós-Graduação em Engenharia de Recursos Hídricos e Ambiental, 2021.

Orientador: Tobias Bernward Bleninger

1. Água – Controle de qualidade. 2. Bacias hidrográficas – Paraná. 3. Abastecimento de água. 4. Reservatórios. I. Universidade Federal do Paraná. II. Bleninger, Tobias Bernward. III. Título.

CDD: 628.16

Bibliotecário: Elias Barbosa da Silva CRB-9/1894



MINISTÉRIO DA EDUCAÇÃO
SETOR DE TECNOLOGIA
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO ENGENHARIA DE
RECURSOS HÍDRICOS E AMBIENTAL - 40001016021P0

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA DE RECURSOS HÍDRICOS E AMBIENTAL da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **JOÃO MARCOS CARVALHO** intitulada: **Matrizes de Transição Como Ferramenta de Análise e Previsão da Qualidade da Água em Reservatórios - Estudo de Caso: Reservatório da UHE Jurumirim**, sob orientação do Prof. Dr. TOBIAS BERNWARD BLENINGER, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 25 de Fevereiro de 2021.

Assinatura Eletrônica

26/02/2021 08:26:34.0

TOBIAS BERNWARD BLENINGER
Presidente da Banca Examinadora

Assinatura Eletrônica

26/02/2021 06:59:30.0

DANIEL HENRIQUE MARCO DETZEL
Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica

26/02/2021 14:22:31.0

FERNANDO MAINARDI FAN
Avaliador Externo (UNIVER. FEDERAL DO RIO GRANDE DO SUL)

Assinatura Eletrônica

26/02/2021 17:32:33.0

CRISTOVÃO VICENTE SCAPULATEMPO FERNANDES
Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Centro Politécnico, Bloco V - CURITIBA - Paraná - Brasil

CEP 81531-990 - Tel: (41) 3361-3210 - E-mail: ppgerha@ufpr.br

Documento assinado eletronicamente de acordo com o disposto na legislação federal Decreto 8539 de 08 de outubro de 2015.

Gerado e autenticado pelo SIGA-UFPR, com a seguinte identificação única: 77690

Para autenticar este documento/assinatura, acesse <https://www.prppg.ufpr.br/siga/visitante/autenticacaoassinaturas.jsp> e insira o código 77690

Dedicatória:

*A boa nutrição e continuidade
da traça que primeiro roeu
as frias folhas do meu TCC
dedico como saudosa lembrança
estas memórias póstumas de uma
Pesquisa.*

AGRADECIMENTOS

Não falarei nenhum nome em específico, pois nesse caso acho que deveria citar pessoas demais e muitas delas eu já não sei o rosto ou nome. Por isso faço esse agradecimento genérico a todos que me aguentaram e que também me deixaram solto.

Espero que entendam que essas palavras toscas não são mera preguiça, mas sim burrice minha em não conseguir compilar um universo de coisas a serem ditas, já que talvez todas essas coisas que me acontecem me fazem ser quem eu sou.

Ademais, agradeço à Agência Nacional de Águas pelo financiamento deste trabalho.

"A ciência é o estupro da realidade"
(Michel Foucault)

RESUMO

Reservatórios de água têm como função permitir uma taxa de controle sobre a variabilidade temporal da disponibilidade hídrica do local em que se encontram, desse modo criando uma maior segurança sobre esse recurso. A qualidade da água desses sistemas deve se apresentar adequada para os seus múltiplos usos, sendo que uma das principais ferramentas para a determinação desse critério é a modelagem matemática, pois não só apresenta excelente custo-benefício frente às demais opções, como também grande capacidade de resolução espacial, temporal e preditiva. Tendo em vista a importância da informação do estado de qualidade em que o reservatório se encontra, buscou-se desenvolver uma análise que leve em conta as aleatoriedades das principais variáveis que podem afetar tanto os regimes térmicos e/ou químicos de um reservatório. Para isso, propõe-se a aplicação de uma análise determinística e estatística conjunta, na qual sejam consideradas as probabilidades de ocorrência de um determinado evento na caracterização da qualidade da água do sistema. Durante a criação da metodologia, foi levada em conta dificultantes como a falta de dados sobre a qualidade da água dos reservatórios e também das demais variáveis necessárias para a implementação de uma modelagem. Essas considerações apresentam a desvantagem de dificultar o processo de representação do reservatório a partir de modelos matemáticos, porém como essa situação é recorrente em todo o globo, o método acaba ganhando força na sua capacidade de abrangência e aplicabilidade. A metodologia da pesquisa pode ser dividida em três grupos, sendo eles: Modelagem, Criação de Cenários e Compilação dos cenários. Por meio da modelagem cria-se um modelo padrão para replicação, possibilitando assim a definição de diferentes cenários, que então são analisados estatisticamente com base nas probabilidades das suas variáveis de entrada, e compilados em um arranjo de uma matriz de transição. Com isso obtêm-se uma ferramenta mais robusta, pouco dependente de medições em campo, de fácil adaptabilidade e replicabilidade para compreender as dinâmicas da qualidade da água em um sistema.

Palavras-chaves: Matriz de transição, Reservatórios, Qualidade da água.

ABSTRACT

Water reservoirs have the function of allowing a rate of control over the temporal variability of the water availability in the region where they are located, thus bringing greater security over these resources. The water quality of these systems must be adequate for their multiple uses, and one of the main tools for this is the mathematical modelling of the system, because it not only presents excellent cost-benefit compared to other options, but also a large capacity for spatial, temporal and predictive resolution. In view of the importance of the water quality state in which the reservoir is, the objective of this work is to develop an analysis that takes into account the randomness of the main variables that can affect both the thermal and/or chemical regimes of a reservoir. For this, it is proposed a combination between a determinist and statistical analysis, where the probabilities of occurrence of a given event are considered within the characterization of the water quality of the reservoir. During the development of the methodology, difficult factors such as the lack of data on the water quality of reservoirs and also of other variables, were considered for the modelling. These considerations present the disadvantage of hindering the representation process of the mathematical models, however, as this situation is recurrent across the globe, the method ends up gaining strength in its reach and applicability. The research methodology can be divided into three groups: Modelling, Creation of Scenarios and Compilation of these scenarios. Though modelling a base layout capable of mass replication is created, thus enabling the definition of different scenarios, which are statistically analysed based on the probabilities of its inputs, and compiled into a state-transition matrix. With this, a more robust tool to understand the dynamics of water quality in a system is obtained, since it is not heavily dependent on field measurements and is easily adaptable and replicable.

Key-words: State-Transition Matrix, Reservoir, Water Quality.

SUMÁRIO

Introdução	10
1.1 JUSTIFICATIVA E RELEVÂNCIA DO TEMA	10
1.2 HIPÓTESE E OBJETIVOS	10
1.3 SÍNTESE DO MÉTODO	11
 Modelagem (Artigo).	 13
 Cenários e Compilação (Artigo).	 28
 Conclusão	 42
 Referências	 44

INTRODUÇÃO

A dissertação apresentada foi escrita no formato de um agrupamento de 2 artigos, portanto a sua estrutura difere da convencional, contudo ainda sim segue as normas estabelecidas pela UFPR para esse tipo de documento.

A ideia que regeu o desenvolvimento do trabalho segue a seguinte pergunta: “Posso usar uma matriz de transição para qualidade da água em um reservatório?”. O documento começa com uma contextualização geral e introdução ao tema, seguido por dois artigos. O primeiro trata dos processos envolvidos durante a etapa de modelagem da qualidade da água do reservatório da UHE Jurumirim, enquanto o segundo explora a criação de uma matriz de transição, utilizando como artifício a cenarização do modelo implementado no primeiro artigo. Cada artigo contém as informações necessárias para o seu entendimento individualizado, sendo que a sua leitura em sequência apenas acrescenta no entendimento do caminho percorrido durante o desenvolvimento da pesquisa.

Ao final do documento há uma conclusão integrada dos artigos, a fim de fazer o fechamento das contribuições, resultados principais e sugestões futuras de desenvolvimento do tema.

1.1 JUSTIFICATIVA E RELEVÂNCIA DO TEMA

Reservatórios de água têm como função permitir o controle sobre a variabilidade temporal da disponibilidade hídrica do local em que se encontram, desse modo criando uma maior segurança sobre esse recurso. A qualidade da água desses sistemas deve se apresentar adequada para os seus múltiplos usos, sendo que uma das principais ferramentas para a determinação desse critério é a modelagem matemática, pois não só apresenta vantagens de custo e benefício, como também grande capacidade de resolução espacial, temporal e preditiva.

1.2 HIPÓTESE E OBJETIVOS

Tendo em vista a importância da informação do estado de qualidade em que o reservatório se encontra, buscou-se desenvolver uma análise que leve em conta as aleatoriedades das principais variáveis que podem afetar tanto os regimes térmicos e/ou químicos de um reservatório.

Para isso, propõe-se a aplicação de uma análise determinística e estatística conjunta, na qual sejam consideradas as probabilidades de ocorrência de um determi-

nado evento na caracterização da qualidade da água do sistema.

Durante a criação da metodologia, foi levada em conta dificultantes como a falta de dados sobre a qualidade da água dos reservatórios e também das demais variáveis necessárias para a implementação de uma modelagem. Essas considerações apresentam a desvantagem de dificultar o processo de representação do reservatório a partir de modelos matemáticos, porém como essa situação é recorrente em todo o globo, o método acaba ganhando força na sua capacidade de abrangência e aplicabilidade.

1.3 SÍNTESE DO MÉTODO

A metodologia da pesquisa pode ser dividida em três grupos, sendo eles: Modelagem, criação de cenários e compilação desses cenários. Por meio da modelagem cria-se um modelo padrão para replicação, possibilitando assim a definição de diferentes cenários, que então são analisados estatisticamente com base nas probabilidades das suas variáveis de entrada, e compilados em um arranjo de uma matriz de transição. Com isso obtêm-se uma ferramenta mais robusta, pouco dependente de medições em campo, de fácil adaptabilidade e replicabilidade para compreender as dinâmicas da qualidade da água em um sistema. O fluxograma da figura 1 ilustra todo o processo.

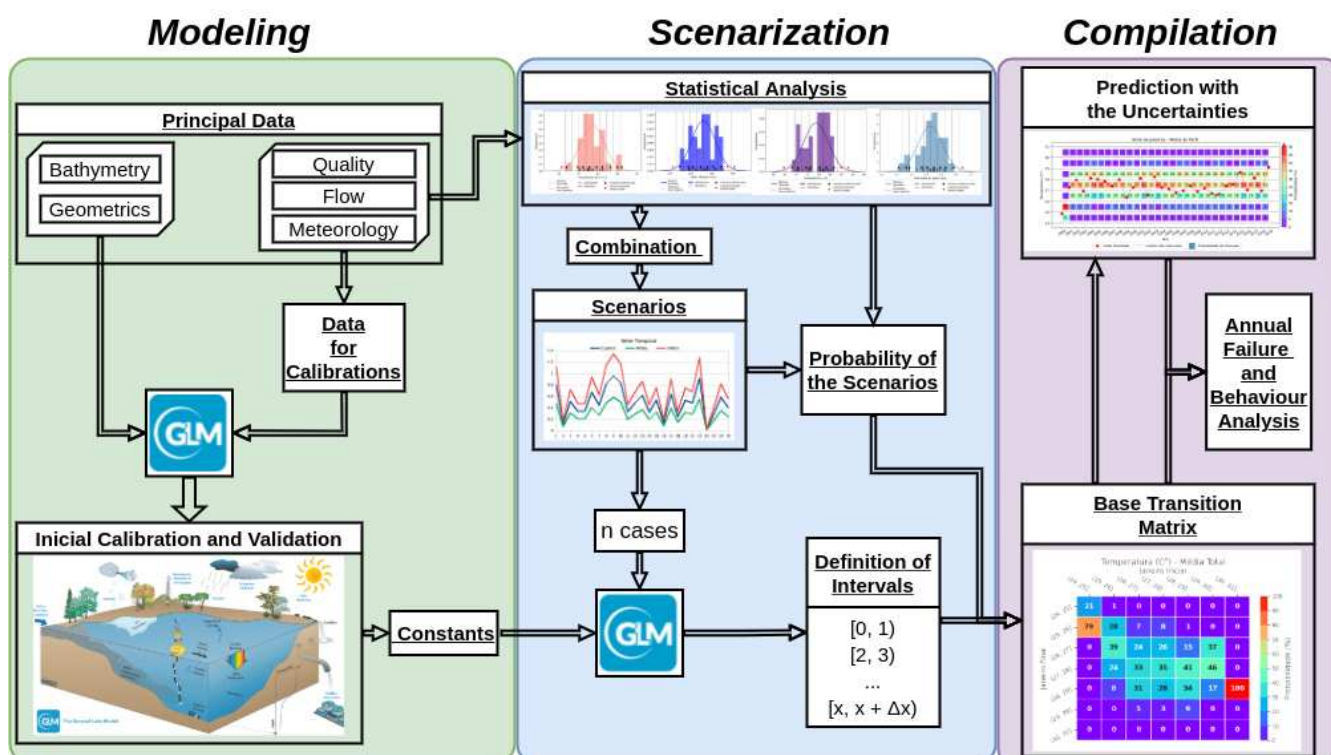


FIGURA 1 – Fluxograma conceitual do trabalho apresentando as 3 etapas adotadas.

Modelagem - Artigo 1

Generalização da Construção de Modelos Térmico/Químico para Reservatórios - Estudo de Caso UHE Jurumirim

João Marcos Carvalho
Orientado

Tobias Bleninger
Orientador

Introdução

Reservatórios são sistemas que têm como principal função diminuir a variabilidade temporal da disponibilidade hídrica de uma região e população. A capacidade de regularização de vazões oferecida pelos reservatórios é fundamental para práticas como a dessedentação de animais, irrigação, abastecimento público, contenção de cheias e geração hidrelétrica (Gomide, 2012).

Em comparação com sistemas fluviais, lagos e reservatórios não possuem diferenças tão acentuadas entre as suas componentes de velocidade e direção de seus fluxos, permitindo a ocorrência de dinâmicas físicas e químicas mais complexas. Devido a isso, novos e diferentes fenômenos são capazes de os afetar de forma significativa, como por exemplo a influência do vento e radiação solar nos processos de mistura, (de Assis Esteves, 1998) e (Bernardo, 2018).

Devido a esse aumento de complexidade, a utilização de métodos de medições *in situ* tradicionais, não possuem capacidade suficiente de avaliar de forma fidedigna a variabilidade temporal e espacial desses sistemas. Métodos de medição de alta frequência como os empregados por (Facchi et al., 2007), (Moraetis et al., 2010), (Chapin, 2015) e (Kozak, 2016) visam diminuir as incertezas dentro da variação temporal através de amostradores automáticos, porém ainda são pouco difundidos e incapazes de resolver os problemas relacionados à grande variação espacial de reservatórios. Junto a isso (Ferreira et al., 2019) ressalta que os métodos de medição tradicionais de qualidade da água, representam apenas um instante de uma condição muito específica, e que caso não ocorra uma mínima sequencialidade de medições, os dados por si só podem falhar na captura do real comportamento do sistema.

Esse tipo de dificuldade acaba tornando necessária a adoção de modelos matemáticos e computacionais para o melhor entendimento do que pode ocorrer dentro dos reservatórios. Tais modelos mesmo sendo muito úteis, já que conseguem gerar uma grande quantidade de informação, ainda possuem exigências para a sua devida funcionalidade; dentre elas está a disponibilidade de informação sobre condições de contorno para o modelo, como por exemplo: vazões afluentes e defluentes, concentração de parâmetros de qualidade da água e dados meteorológicos.

Tendo em mente as limitações referentes aos dados de entrada para modelos matemáticos, esse artigo propõe alguns

métodos para a complementaridade de dados faltantes para a modelagem de um reservatório; como regressões lineares para geração de dados de temperatura da água, usando dados de temperatura do ar, (Colombo, 2019); e também a geração de séries sintéticas como método de interpolação de dados de qualidade da água, Ferreira (2019). Desse modo o trabalho contribui na exploração de abordagens alternativas para a modelagem de reservatórios.

Como estudo de caso foi usado o reservatório da Usina Hidrelétrica (UHE) Jurumirim, sendo ele o primeiro grande reservatório da cascata do rio Paranapanema. Ele foi escolhido, pois o seu estudo faz parte e foi financiado pelo projeto de P&D, entre a Universidade Federal do Paraná (UFPR) e a Agência Nacional de Águas (ANA), referente ao enquadramento hidrodinâmico da bacia do rio Paranapanema.

Como ferramenta de modelagem foi utilizado o General Lake Model (GLM), sendo ele um modelo em estado da arte para avaliações térmicas e hidrodinâmicas de reservatórios. O modelo é unidimensional verticalmente, de modo a considerar o reservatório como uma série de reatores empilhados capazes de realizar trocas entre si e com os contornos. Devido a esse tipo de representação o GLM é útil para lagos e reservatórios profundos, já que desse modo pode melhor avaliar os processos de estratificação térmica e química normalmente presentes nesses sistemas.

O modelo apresenta uma grande aplicabilidade em diferentes tipos de sistemas, já tendo sido usado tanto para lagos e reservatórios de pequeno a grande porte Bruce et al. (2018), Hipsey et al. (2019), Fenocchi et al. (2019) e Prats et al. (2018). O GLM também possui um rápido tempo de processamento, contribuindo para estudos que necessitam de um alto número de cenários e também processos de calibração automatizados (Jia et al., 2019). Outro fator que contribuiu para a escolha desse modelo foi a sua replicabilidade, já que é um software de código aberto e gratuito, facilitando a sua aplicação em diversas regiões do mundo e fortalecendo a comunidade que colabora, desenvolve e trabalha com ele.

Materiais e Métodos

Modelagem de Reservatórios

Para a análise de reservatórios, a modelagem é uma das principais ferramentas existentes (Orlob, 1983) e (Hipsey et al., 2019), pois apresenta custo-benefício superior frente

às demais opções, além de grande capacidade de resolução espacial e temporal. A modelagem computacional normalmente se utiliza de dados de campo para suas condições de contorno, calibração e validação, contudo a dificuldade de obtenção desses dados normalmente é elevada, quando comparado com a capacidade de resposta ofertada por modelos matemáticos. A capacidade de gerar informações por meio de modelos com maior resolução que o monitoramento, além de auxiliar no entendimento do sistema com indicadores de alta resolução temporal, é um fator essencial para a gestão de recursos hídricos (Luckner, 2018), já que possibilita o seu melhor entendimento. Dados que acompanham a grande variabilidade temporal da qualidade de água são úteis, já que permitem um maior entendimento dos resultados dos fenômenos físicos ocorridos. A partir disso, o processo de tomada de decisão, ação, determinação de medidas de manutenção do corpo hídrico e gestão da qualidade ganha um aumento de eficiência e velocidade.

UHE Jurumirim

Foi feita a modelagem unidimensional da qualidade d'água para o reservatório da UHE Jurumirim, tendo ele um volume de 7007.1 hm^3 , profundidade máxima de operação de 38 m e área inundada de 499 km^2 . O reservatório possui uma capacidade de regularização interanual, tendo usos diversos como geração de energia hidrelétrica, aquicultura e regularização do rio Paranapanema. A geração de energia é a sua função mais preponderante, possuindo uma potência instalada de 100.9 MW . O reservatório está inserido na bacia do rio Paranapanema, dentro do estado de São Paulo, Brasil.

Esse corpo hídrico possui dois grandes afluentes, os rios Paranapanema e Taquari, responsáveis por mais de 80% da vazão afluente total, tendo o primeiro as vazões mais expressivas que o segundo. O nível d'água e vazão afluente média de longo termo do reservatório são 35.6 m e $255 \text{ m}^3/\text{s}$, respectivamente. A bacia hidrográfica possui cerca de 17.900 km^2 , sendo o comprimento do rio Paranapanema até início do reservatório de 321.2 km .

As informações utilizadas para a sua modelagem foram as séries temporais de qualidade da água e morfologia, dados fluviométricos e dados meteorológicos, sendo eles extraídos das seguintes fontes respectivamente: ANA (2019), companhia operadora do reservatório (CTG-Brasil) e modelo meteorológico de reanálise CFSR (Saha et al., 2010) e (Saha et al., 2011). A figura 1 apresenta o reservatório junto com os pontos geográficos das séries temporais que foram utilizadas para a sua modelagem.

General Lake Model - GLM

O General Lake Model (GLM) é um modelo de código aberto e unidimensional para a solução do balanço de massa, energia e calor em lagos naturais e artificiais (Hipsey et al.,

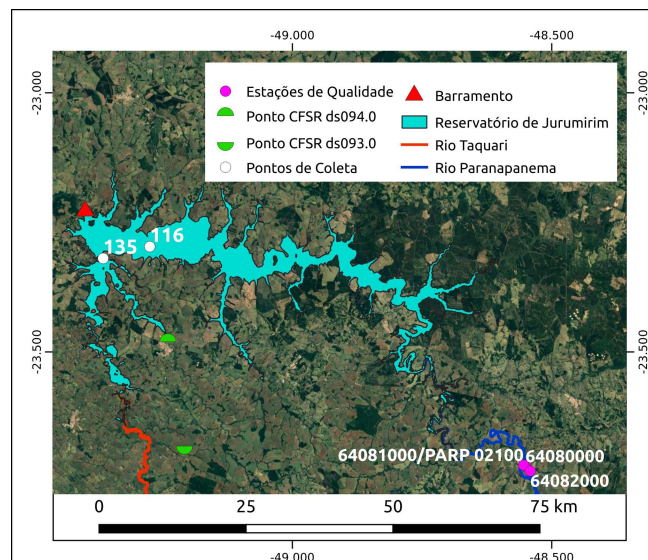


Figura 1. Posicionamento do reservatório e local das séries utilizadas.

2019). Ele foi desenvolvido pela Aquatic Ecodynamics research group (AED) da Universidade do Leste da Austrália por meio da iniciativa e colaboração do GLEON (2020), e a AEMON (2020).

O modelo possui um rápido tempo de execução - cerca de segundos para simular 1 ano - e pode ser integrado a diversos modelos de qualidade da água como LakeAnalyser (LA) (Read et al., 2011), Framework for Aquatic Biogeochemical Models (FABM) e Aquatic Ecodynamics (AED2) (Brugge-man & Bolding, 2014), complementando assim as suas análises. O modelo é ideal para sistemas com pouca variação horizontal, já que é 1D verticalmente; e apresenta grande velocidade para modelagens de grandes períodos de tempos ou de diversos cenários de análise (Hipsey et al., 2019).

A quantidade de informações de entrada que o modelo pode absorver é elevada e pode ser vista pelo desenho didático da figura 2, entretanto dado a sua maleabilidade, nem todos esses dados são essenciais, dependendo apenas do grau de complexidade requisitado por cada projeto.

O modelo aqui implementado não utilizou dados de nebulosidade e de radiação solar - pois esta foi calculada pelo próprio GLM utilizando a umidade relativa, temperatura do ar e latitude do reservatório. Essa escolha foi feita pois pretende-se ter uma modelagem o mais simples possível. Por fim, os dados sobre a chuva encontram-se indiretamente dentro do balanço hídrico dos dados de vazão, como será mostrado mais a frente.

Vale lembrar que o objetivo do trabalho é tornar mais fácil a modelagem de reservatórios, frente a dificuldade que é a relativa falta de dados disponíveis para esses sistemas; portanto as simplificações reforçam esse objetivo sem necessa-




Figura 2. Esquema didático com os parâmetros necessários para o modelo.

riamente comprometer a qualidade da modelagem.

Séries Temporais Necessárias

Vazões. Os dados sobre o balanço hídrico do reservatório utilizados foram obtidos diretamente da CTG Brasil, a empresa responsável pela operação e exploração hidrelétrica do sistema em questão. Os dados obtidos foram os de vazão afluente, defluente e o nível medido no barramento, sendo eles disponibilizados em escala horária para o período entre 1988 e 2019; posteriormente os dados foram transformados em médias diárias. Apenas os dados de vazões defluentes e nível são dados totalmente medidos pela empresa, de modo que a vazão afluente total é calculada através de um balanço hídrico utilizando a curva Cota x Área x Volume (CAV) do reservatório, nível e vazão defluente. A equação 1 apresenta como o balanço é feito.

$$Q_{in\ t_i} = Q_{out\ t_i} - (Vol_{t_i} - Vol_{t_{i-1}}) \quad (1)$$

onde, $Vol_t = f(H_t)$

Tal tipo de dado facilita a utilização do GLM, já que não é necessária nenhuma calibração do modelo, do ponto de vista do balanço hídrico, pois basta que seja feito o desligamento dos módulos responsáveis pelos processos de evaporação e infiltração que ocorrem no reservatório. O desligamento desses módulos não altera nenhuma outra propriedade dos fluxos internos do modelo, somente conservam a massa de água no sistema. As figuras 3 e 4 apresentam as vazões afluentes, defluentes e curva CAV do reservatório, enquanto a tabela 1 contém a média, desvio padrão e os 1º, 2º e 3º três quartis das séries diárias.

Vale comentar dois pontos interessantes sobre o balanço hídrico do reservatório. Dado a abordagem usada para determinar as vazões afluentes, valores negativos podem/ocorrem nos dados de afliência, como é observado na figura 3. Como vazões negativas são fisicamente impossíveis nesse tipo de sistema, e podem causar problemas para a modelagem computacional, todos os dias com vazões negativas foram consi-

derados com vazões igual a zero. O segundo ponto é referente aos valores médios das vazões afluentes e defluentes, pois a vazão defluente é $1\text{ m}^3/\text{s}$ superior a afluente, o que também pode ser visto como incoerente, já que teoricamente a vazão defluente deveria ter no máximo o valor da vazão afluente, para que o reservatório não viesse a esvaziar. Contudo isso pode ser explicado, pois os dados são apenas uma amostra e possuem influência do método de cálculo da vazão afluente; portanto diferenças dessa magnitude entre as vazões podem ser esperadas.

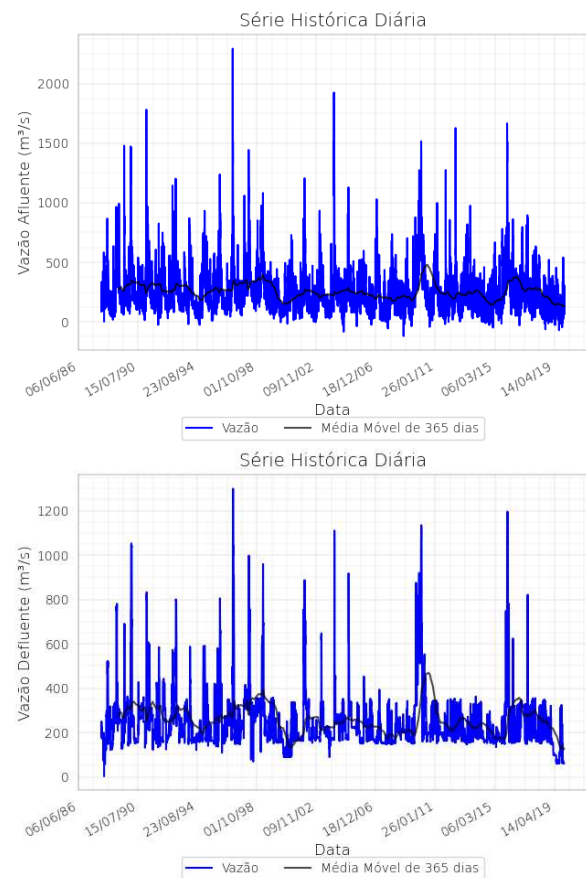


Figura 3. Série histórica de vazões afluentes (acima) e defluentes (abaixo).

Velocidade do Vento, Umidade e Temperatura do ar.

Os dados meteorológicos de velocidade do vento, umidade específica e temperatura do ar foram obtidos do modelo meteorológico Climate Forecast System Reanalysis (CFSR), tendo ele dados de 1979 até o presente, com escalas temporais de 1 hora, 6 horas e 1 mês.

A série de dados utilizada se encontra entre os anos de 1979 a 2019, sendo necessário a utilização de duas versões do modelo, a CFSR ds093.0 e a CFSv2 ds094.0, pois a primeira possui dados entre 1979 e 2010, enquanto a segunda entre 2010 e o presente. O intervalo de tempo das séries é de

Tabela 1
Parâmetros estatísticos das séries de vazões, nível do reservatório.

Métrica	Vazão Afluente (m^3/s)	Vazão Defluente (m^3/s)	Nível (m)
Média	256	257	35.6
Desvio Padrão	189	142	1.6
1° Quartil	142	166	35
2° Quartil	205	222	36
3° Quartil	316	314	37




Figura 4. Curva Cota x Área x Volume.

6 horas, porém assim como os dados de vazões e níveis elas foram transformadas em médias diárias.

As diferentes versões possuem também diferentes espaçamentos de grades para os seus dados, logo dois pontos geográficos foram assumidos como representativos do reservatório, sendo eles o ponto 23.26S, 311.56L e o 23.2S e 311.32L, onde primeiro é referente a versão CSFR ds093.0 (Saha et al., 2011) e o segundo a versão CFSv2 ds094.0 (Saha et al., 2010).

O modelo não fornece dados de umidade relativa do ar, porém eles foram estimados através da equação 2, sendo ela um caso específico da equação de Clausius-Clapeyron aplicado à meteorologia. A equação possui como variáveis de entrada a velocidade do vento, temperatura do ar, umidade específica do ar e pressão atmosférica.

$$U_{Rel} = 100 \frac{U_{Esp} P}{0.622 e_s} \quad (2)$$

$$\text{onde, } e_s = 6.11 e^{\frac{17.67T}{T+243.51}}$$

Sendo:

- U_{Rel} = Umidade relativa (%)
- U_{Esp} = Umidade específica (g/Kg)

- T = Temperatura do ar ($^{\circ}\text{C}$)
- P = Pressão atmosférica (hPa)

O posicionamento dos pontos escolhidos do modelo CFSR estão presentes na figura 1, enquanto que os gráficos das séries de temperatura do ar, umidade relativa do ar e velocidade do vento se encontram na figura 5. A tabela 2 contém a médias, desvio padrão e quartis da séries diárias.

Temperatura da Água (Afluência). Os dados de temperatura da água afluente ao reservatório são pouco mais de 300 medições em 40 anos, para o rio Paranapanema. Essa quantidade é baixa quando comparada a quantidade de dias de todo esse período, sendo essa uma situação recorrente para a temperatura da água, mesmo este sendo um parâmetro pouco custoso para ser amostrado, do ponto de vista técnico e econômico. Entretanto Colombo (2019) mostra a capacidade de estimação desta temperatura através de uma regressão linear simples da média móvel da série histórica de temperatura do ar.

Utilizando esse método foram feitas regressões comparando os dados medidos de temperatura da água das estações 64080000, 64081000 e 64082000, com a média móvel das medições de temperatura do ar do modelo CFSR. Essas estações de temperatura da água foram escolhidas por serem as mais próximas da entrada do rio Paranapanema no reservatório de Jurumirim. A figura 1 mostra a posição das estações de temperatura da água, sendo a sua distância aproximada até a entrada do reservatório de 20 km.

Além da combinação da série de dados meteorológicos com as três estações de temperatura da água, foram testadas médias móveis de 1 a 25 dias e 9 funções de ponderação da média móvel. A figura 6 apresenta o esquema da geração de todos os modelos, enquanto a equação 3 mostra a sua formulação.

$$T_{\text{água}} = ax + b + \epsilon \quad (3)$$

$$\text{onde, } x = f_{\text{ponderao}}(MM(T_{Ar}))$$

O modelo de médias móveis (MMM) mais próximo dos dados medidos foi escolhido com a ajuda de quatro métricas:

Tabela 2
Parâmetros estatísticos das séries de temperatura do ar, umidade relativa e velocidade do vento.

Métrica	Temperatura do Ar ($^{\circ}\text{C}$)	Umidade Relativa (%)	Velocidade do Vento (m/s)
Média	19.7	79	2.4
Desvio Padrão	3.5	13	0.9
1° Quartil	17.4	71	1.8
2° Quartil	20.2	82	2.3
3° Quartil	22.3	89	3.0




Figura 5. Séries históricas de temperatura do ar, umidade relativa e velocidade do vento.

coeficiente de determinação ajustado e não ajustado, o erro médio absoluto e o erro médio quadrático, além da comparação visual das séries geradas e medidas. Com essa análise chegou-se no MMM para 6 dias com ponderação uniforme (média móvel simples).

A figura 7 apresenta as métricas dos MMM para a estação 64081000. Dada a quantidade de informação gerada, optou-se por traduzir os resultados em forma de mapas de calor, sendo o eixo y o nome do método de ponderação, e x o número de dias usados na média móvel; desse modo a escala de cores da métrica facilita a visualização dos resultados de

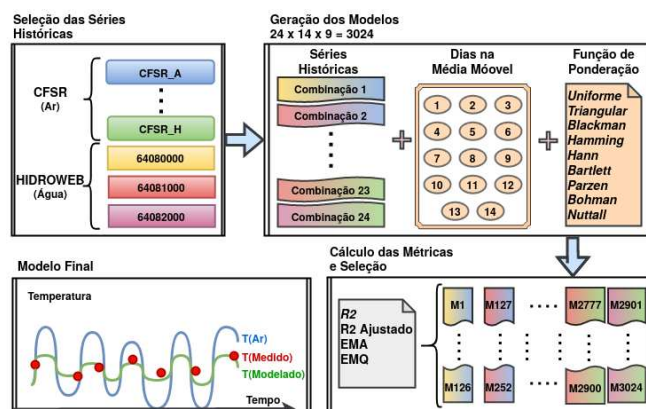


Figura 6. Fluxograma da geração dos MMM testados.

cada modelo de forma integrada.

Como muitos modelos possuem métricas semelhantes, a comparação direta entre as séries também foi feita como forma complementar. A figura 8 mostra a comparação entre a série calculada com a média móvel de 6 dias e a série medida.

Mesmo as métricas não atingindo valores de ajuste altos, como coeficientes de determinação superiores a 0.9 e erros abaixo de 0.5 °C, observa-se que o comportamento geral da série foi respeitado, validando essa abordagem.

Uma das causas do ajuste não tão efetivo do método para o rio Paranapanema é o seu grande porte, pois como comentado por Colombo (2019), a utilização da média móvel da temperatura do ar é mais efetiva em rios de menores dimensões, já que possuem uma menor influência do escoamento subterrâneo, que normalmente é menos afetado pela temperatura do ar.

Qualidade da Água. A inexistência de séries de parâmetros de qualidade da água com boa resolução temporal e quantidade amostral suficiente é mais uma situação comum na modelagem de reservatórios, muitas vezes forçando o modelador a utilizar valores médios como artifício de substituição. Tendo em vista essa dificuldade nas séries de qualidade da água, optou-se pela utilização do método proposto por Ferreira (2019) para contornar esse problema.

O método consiste na geração de diversas séries utilizando um modelo markoviano, e posteriormente selecionando a que melhor se ajusta aos dados originais. Essa abordagem apresenta duas vantagens, sendo elas a não alteração das propriedades estatísticas dos dados originais e a incorporação de pulsos que melhor descrevem as dinâmicas temporais das séries. De forma breve, o método gera séries horárias utilizando o modelo markoviano, equação 4, com o coeficiente de autocorrelação de 0.9, (Ferreira, 2019). Posteriormente a série horária tem sua escala alterada para médias diárias, e os resultados são comparados com os dados amostrados.




Figura 7. Métricas dos MMM entre dados do CFSR e estação 64081000.

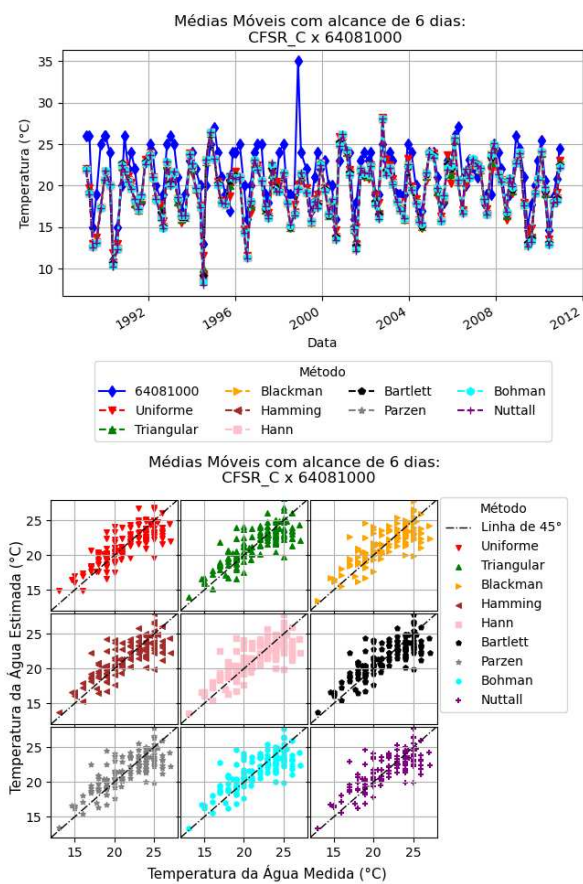


Figura 8. Resultados do MMM de 6 dias com os dados medidos e a estação 64081000.




Figura 9. Série estimada de temperatura da água.

$$Par_t = \mu + \rho(Par_{t-1} - \mu) + a_t\sigma\sqrt{1 - \rho^2} \quad (4)$$

Par: Variável temporal

μ : Média dos dados originais

σ : Variância dos dados originais

ρ : Coeficiente de correlação linear

a : Ruído pseudo-aleatório normalmente distribuído $N(0,1)$

Foram geradas cerca de 2000 séries com o mesmo comprimento de uma série horário com dados entre os anos de 1950 e 2019; cada série teve um incremento de 20% no seu tamanho inicial para fins de aquecimento do modelo, sendo esse acréscimo posteriormente descartado. As séries foram geradas tanto utilizando diretamente os dados, quanto aplicando uma transformação logarítmica. As métricas adotadas para selecionar o melhor ajuste foram: Kolmogorov-Smirnov (KS), Erro Médio Absoluto (MAE), Erro Médio Quadrático (MSE) e Raiz do Erro Médio Quadrático (RMSE); sendo elas aplicadas tanto na série temporal, quanto para os quartis entre 5% até 95%, em intervalos de 5%, das distribuições de probabilidade empíricas das séries.

Os parâmetros de qualidade da água utilizados foram oxigênio dissolvido (OD), nitrato (NO_3), nitrogênio amoniacal (NH_3) e fósforo total (PT), sendo eles obtidos também das estações 64080000, 64081000 e 64082000 do hidroweb e PARP 02100 da CETESB-SP. A figura 10 mostra os dados medidos junto com a série gerada selecionada, enquanto que a figura 11 apresenta as distribuições de probabilidades das séries. Retirando OD, todos os demais parâmetros obtiveram séries sintéticas estatisticamente mais semelhantes a série observada quando utilizada a transformação logarítmica.

Tempo de Aquecimento

Em modelos computacionais de reservatórios, a solução das equações matemáticas que nele se encontram, exige a definição de condições iniciais para todos os parâmetros simulados. Algumas delas, como o nível inicial, podem ser facilmente obtidas, porém dados qualitativos, como perfis de temperatura e de concentrações, são comumente mínimos ou inexistentes em reservatórios. Além disso, perfis medidos em campo também são necessários para que seja feita a calibração e validação do modelo; desse modo esse tipo de dado passa a ser disputado por três etapas de modelagem: condição inicial, calibração e validação.

O reservatório da UHE Jurumirim é um dos que sofrem com esse tipo de problema, já que possui apenas alguns perfis medidos de temperatura e concentração de OD, NO_3 , PT nos meses de março, abril e setembro de 2011. Dada essa condição recorrente em outros reservatórios, estudou-se a utilização de uma condição inicial pouco impactante, ou seja: uma condição inicial que não seja capaz de causar perturbações significativas no período analisado do modelo.




Figura 10. Série de dados e sintética.




Figura 11. Comparação entre as distribuições de probabilidade.

A condição inicial aqui estudada não se baseou diretamente na criação de um perfil do parâmetro analisado, mas sim no tempo que o reservatório leva para não sofrer influência da condição inicial. Sendo assim, como em muitos casos, foi utilizado um perfil médio uniforme, porém considerado um tempo de aquecimento no modelo. Esse tempo de aquecimento é definido como: O tempo necessário para que o sistema não seja mais afetado pela condição inicial em que se encontrava, ou em outras palavras, o tempo para que o reservatório "esqueça" como ele era no início da modelagem.

Para a determinação desse tempo estipulou-se um dia fixo de comparação e n dias iniciais de modelagem, de modo que foram rodados n modelos com n tempos de aquecimento em relação ao dia fixo. Com esse dia fixo, foi feita a comparação entre os perfis de cada parâmetro e observada a quantidade de dias necessária para não ocorrer grandes mudanças no modelo. A figura 12 exemplifica o processo.




Figura 12. Exemplo da determinação do tempo de aquecimento do GLM.

Os testes de memória foram feitos para o perfil inicial de temperatura, oxigênio dissolvido, nitrogênio amoniacal, nitrato e fósforo total, considerando um perfil uniforme, com os seguintes valores para os parâmetros: 21 °C, 7 mgO₂/l, 0.28 mgN/l, 0.11 mgN/l e 0.06 mgP/l, respectivamente. A figura 13 apresenta os perfis encontrados para os 5 parâmetros, sendo o tempo, em dias, de aquecimento necessário para cada um deles de: 90, 70, 70, 50 e 90 respectivamente.

Para esse processo foi criada uma rotina em linguagem de programação *python* para a execução em série de cada tempo de aquecimento. Foram testados cerca de 147 períodos, estando eles entre 0 e 730 dias, com intervalos de 5 dias entre si. A rotina consiste de 4 passos: Alteração do dia e nível iniciais da modelagem; inicialização do GLM; retirada dos dados do dia de comparação; repetição dos passos anteriores 3 passos até acabar o período de análise.

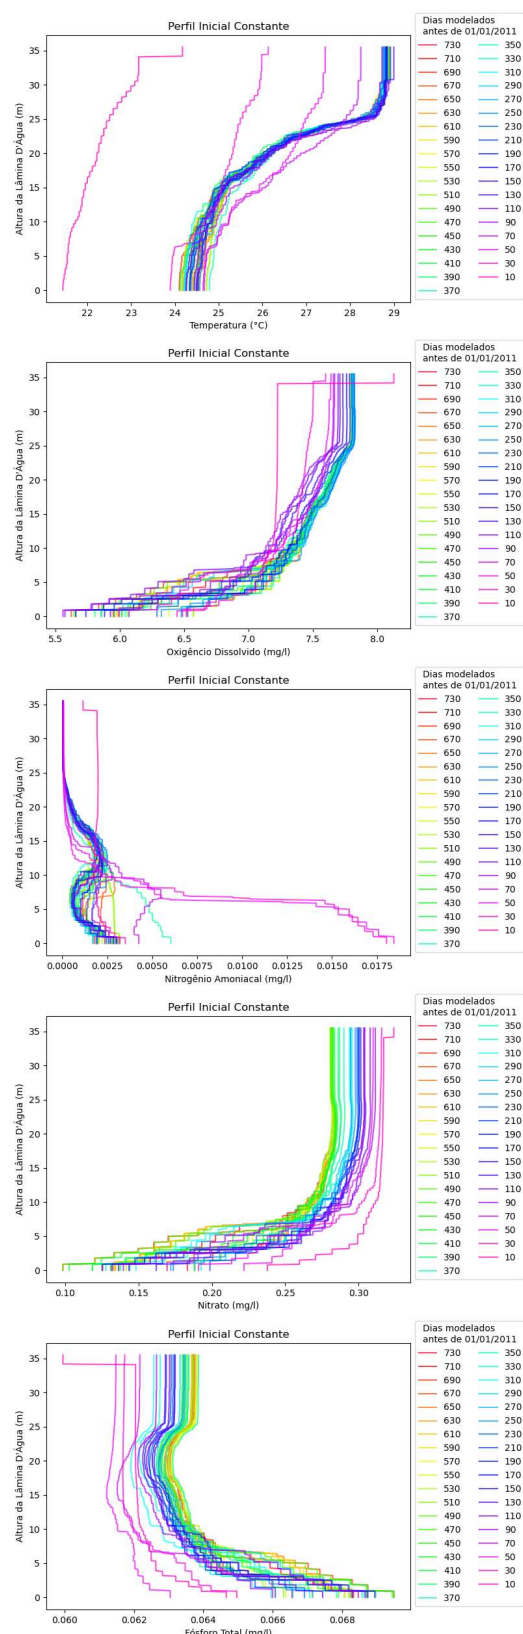


Figura 13. Memória do reservatório em relação aos dados de temperatura, oxigênio, nitrato e fósforo iniciais.

Modelagem e Calibração

A modelagem final foi feita para o período entre 1990 e 2018, sendo utilizado um tempo de aquecimento de 1 ano por conveniência de configuração do modelo; sendo esse valor quase 4 vezes maior que o tempo de aquecimento mínimo estimado. O modelo foi calibrado utilizando perfis de temperatura e qualidade da água medidos em 2011, sendo esses os únicos dados disponíveis sobre a qualidade da água no reservatório.

Para o processo de calibração foi criada uma rotina em python onde um modelo base era executado em série, sendo que para cada nova execução apenas o valor de uma determinada variável era alterado em relação ao modelo base. Como forma de avaliação de cada execução do GLM um gráfico comparando os perfis calculados e medidos era gerado e o erro médio absoluto (EMA) calculado. A lista a seguir apresenta simplificada os processos envolvidos.

- Separação de um modelo base
- Identificação das variáveis de calibração
- Criação de uma lista de valores possíveis para as variáveis de calibração
- Iteração entre as variáveis
 - Iteração entre os valores possíveis da variável
 - * Criação de um novo modelo com o novo valor da variável
 - * Execução do modelo
 - * Geração do gráfico de comparação
 - * Adição do Erro Médio Absoluto (EMA) ao gráfico
- Atualização do modelo base
- Repetição do processo até se observado a convergência do modelo

Para a identificação dos coeficientes com maior impacto no sistema, antes da calibração foi executado uma análise de sensibilidade das variáveis do modelo hidrodinâmico e térmico, sendo que na tabela 3 se encontram as variáveis utilizadas com os seus intervalos. O princípio de utilização de uma modelo base e da alteração de apenas uma variável por vez foi mantido durante essa análise. O modelo base inicial utilizou os valores padrões do GLM e a avaliação dos efeitos gerados foi visual.

A partir da análise de sensibilidade foram definidos os parâmetros de calibração, que estão presentes na tabela 4; nessa mesma tabela também se encontram as variáveis referentes ao modelo de qualidade da água AED2.

O processo de calibração foi feito em duas etapas em série: Calibração do modelo GLM (processos hidrodinâmicos

Variável	Mín.	Máx.	Δ
<i>max_layers</i>	200	1000	100
<i>min_layer_thick</i>	0.01	0.5	0.025
<i>max_layer_thick</i>	0.5	2	0.2
<i>Kw</i>	0.1	10	1
<i>strm_hf_angle</i>	50	130	10
<i>strmbd_slope</i>	0.1	2	0.1
<i>strmbd_drag</i>	0.006	0.05	0.005
<i>surface_mixing</i>	0	2	1
<i>coef_mix_conv</i>	0.05	0.5	0.05
<i>coef_wind_stir</i>	0.05	0.5	0.05
<i>coef_mix_shear</i>	0.1	0.5	0.1
<i>coef_mix_turb</i>	0.3	0.7	0.1
<i>coef_mix_KH</i>	0.1	0.5	0.1
<i>deep_mixing</i>	0	2	1
<i>coef_mix_hyp</i>	0.3	0.7	0.1
<i>lw_factor</i>	0.7	1.3	0.1
<i>sw_factor</i>	0.7	1.3	0.1
<i>wind_factor</i>	0.7	1.3	0.1
<i>rh_factor</i>	0.7	1.3	0.1
<i>at_factor</i>	0.7	1.3	0.1
<i>ce</i>	0.001	0.0016	0.0001
<i>ch</i>	0.001	0.0016	0.0001
<i>cd</i>	0.001	0.0016	0.0001
<i>Oz</i>	0.2	0.4	0.1
<i>WatVap</i>	0.7	1.5	0.2
<i>AOD500</i>	0.01	0.045	0.01
<i>AOD380</i>	0.01	0.05	0.01
<i>Albedo</i>	0.05	0.5	0.05
<i>bsn_len</i>	50000	140000	10000
<i>outl_elvs</i>	540	565	5
<i>bsn_len_outl</i>	10000	80000	10000
<i>bsn_wid_outl</i>	100	900	100

Tabela 3

Variáveis utilizadas na análise de sensibilidade e os seus valores mínimos, máximos e delta utilizado para a criação de cada lista de valores adotados.

e térmicos) e calibração do modelo AED2 (processos químicos). O algoritmo de calibração foi aplicado 4 vezes seguidas para cada um dos modelos, sendo que para cada nova execução o modelo base era atualizado com os melhores resultados da calibração anterior. As quatro repetições do algoritmo foram determinadas com base na convergência do modelo. Finalizado todo essa etapa automatizada do processo de calibração, alguns ajustes foram feitos de forma manual.

As tabelas 5 e 6 apresentam as configurações das variáveis utilizadas no modelo final para o GLM e AED2. Ao total, mais de 5000 cenários foram executados nas etapas de calibração e análise de sensibilidade.

A figura 14 mostram os resultados obtidos na calibração, sendo que as linhas pontilhadas representam os dados me-

Modelo	Variável	Mín.	Máx.	Δ
GLM	<i>Albedo</i>	0	0.4	0.05
	<i>strm_hf_angle</i>	70	110	5
	<i>strmbd_slope</i>	0.1	0.9	0.1
	<i>strmbd_drag</i>	0.012	0.02	0.002
	<i>KW</i>	0.3	0.7	0.05
	<i>outl_elvs</i>	530	570	5
	<i>lw_factor</i>	0.6	1	0.05
	<i>sw_factor</i>	0.6	1	0.05
	<i>wind_factor</i>	0.8	1.2	0.05
	<i>coef_mix_conv</i>	0	0.4	0.05
	<i>coef_mix_turb</i>	0.1	0.9	0.1
	<i>coef_mix_hyp</i>	0.1	0.9	0.1
AED2	<i>Fsed_oxy</i>	-100	0	10
	<i>Ksed_oxy</i>	-100	200	10
	<i>theta_sed_oxy</i>	0.4	1.8	0.05
	<i>Rnitrif</i>	0	0.5	0.1
	<i>Knitrif</i>	0	100	10
	<i>theta_nitrif</i>	0.4	1.8	0.1
	<i>Rdenit</i>	0	0.8	0.1
	<i>Kdenit</i>	1	3	0.2
	<i>theta_denit</i>	0.4	1.8	0.1
	<i>Rdnra</i>	0	0.1	0.01
	<i>Kdnra_oxy</i>	0	10	0.5
	<i>Fsed_ammv</i>	-10	10	0.5
	<i>Ksed_amm</i>	-50	50	5
	<i>Fsed_nit</i>	-10	10	1
	<i>Ksed_nit</i>	-200	200	10
	<i>theta_sed_amm</i>	0.4	1.8	0.1
	<i>theta_sed_nit</i>	0.4	1.8	0.1
	<i>Fsed_frp</i>	0	0.2	0.02
	<i>Ksed_frp</i>	-100	100	10
	<i>theta_sed_frp</i>	0.4	1.8	0.1

Tabela 4

Variáveis utilizadas na calibração em conjunto com os seus valores mínimos, máximos e delta utilizado para a criação de cada lista de valores adotados.

didos e as contínuas os dados calculados. como a escala temporal se perde nessa representação a figura 15 complementa a análise apresentando a distribuição espaço-temporal dos dados medidos junto com o mapa de calor modelado ao fundo.

Os perfis calculados apresentaram erros médios de 1.54°C, 0.79mg/l, 0.14mg/l e 0.04mg/l, respectivamente para temperatura da água, concentração de oxigênio, nitrato e fósforo total. Excluindo os resultados para fósforo, os perfis calculados seguiram os mesmos padrões médios apresentados pelos dados medidos.

As divergências entre os dados amostrais e calculados podem ter ocorrido não só devido a problemas de calibração e limitações do modelo, mas também com a não consistência




Figura 14. Perfis modelados vs medidos nos pontos ID 135 e ID 116.

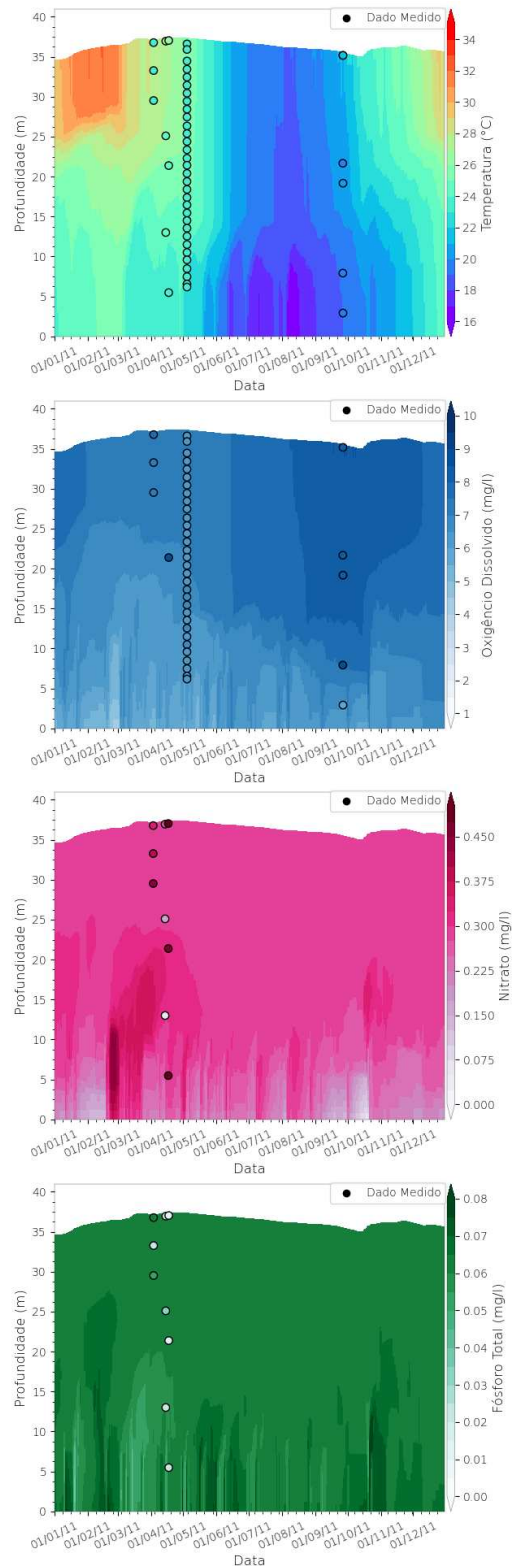


Figura 15. Dados medidos em campo, junto com os resultados do modelo.

Variável	Valor Usado	Variável	Valor Usado
<i>max_layers</i>	300	<i>sw_factor</i>	0.85
<i>min_layer_vol</i>	0.025	<i>lw_factor</i>	0.85
<i>min_layer_thick</i>	0.1	<i>rh_factor</i>	1
<i>max_layer_thick</i>	1.5	<i>at_factor</i>	1
<i>density_model</i>	1	<i>wind_factor</i>	0.6
<i>non_avg</i>	.true.	<i>rain_factor</i>	1
<i>wq_lib</i>	'aed2'	<i>ce</i>	0.0013
<i>ode_method</i>	1	<i>ch</i>	0.0013
<i>split_factor</i>	1	<i>cd</i>	0.0013
<i>bioshade_feedback</i>	.true.	<i>fetch_mode</i>	0
<i>repair_state</i>	.true.	<i>light_mode</i>	0
<i>surface_mixing</i>	0	<i>Kw</i>	0.5
<i>coef_mix_conv</i>	0.4	<i>AP</i>	928
<i>coef_wind_stir</i>	0.23	<i>Oz</i>	0.273
<i>coef_mix_shear</i>	0.3	<i>WatVap</i>	1.1
<i>coef_mix_turb</i>	0.51	<i>AOD500</i>	0.033
<i>coef_mix_KH</i>	0.3	<i>AOD380</i>	0.038
<i>deep_mixing</i>	1	<i>Albedo</i>	0.05
<i>coef_mix_hyp</i>	0.5	<i>num_inflows</i>	1
<i>diff</i>	0	<i>subm_flag</i>	.false.
<i>latitude</i>	-23.21083	<i>strm_hf_angle</i>	85
<i>longitude</i>	-49.22917	<i>strmbd_slope</i>	0.5
<i>crest_elev</i>	569.5	<i>strmbd_drag</i>	0.016
<i>bsn_len</i>	90982	<i>inflow_factor</i>	1
<i>bsn_wid</i>	433.7	<i>inflow_varnum</i>	7
<i>bsn_vals</i>	11	<i>num_outlet</i>	1
<i>met_sw</i>	.true.	<i>outflow_factor</i>	1
<i>subdaily</i>	.true.	<i>outlet_type</i>	1
<i>rain_sw</i>	.false.	<i>outl_elvs</i>	555
<i>atm_stab</i>	0	<i>bsn_len_outl</i>	90000
<i>cloud_mode</i>	1	<i>bsn_wid_outl</i>	300
<i>rad_mode</i>	5	<i>seepage</i>	.false.
<i>albedo_mode</i>	3	<i>disable_evap</i>	.true.

Tabela 5

Parâmetros de configuração do modelo GLM.

dos dados de campo. Outra explicação é o fato de que o modelo está em escala diária e os dados medidos em escala horária, fazendo com que o modelo amortize picos que as medições podem vir a carregar. A calibração visou manter um padrão tanto com os perfis medidos, mas também com situações vistas em literatura para reservatórios de mesma profundidade - (de Assis Esteves, 1998) e (Read et al., 2014) - como o decréscimo da temperatura, oxigênio e nitrato ao longo do perfil.

Fica a ressalva para a modelagem de fósforo, que foi muito diferente do que se observou em campo, e não pode ser explicada somente com as diferenças de escalas temporais e não consistência de dados. Uma das possíveis causas dessa discrepância pode ser os dados de entrada que geraram

Variável	Valor Usado	Variável	Valor Usado
<i>oxy_initial</i>	250	<i>theta_denit</i>	1.08
<i>Fsed_oxy</i>	-100	<i>Rdnra</i>	0.01
<i>Ksed_oxy</i>	150	<i>Kdnra_oxy</i>	2
<i>theta_sed_oxy</i>	1.08	<i>Fsed_amm</i>	3.5
<i>oxy_min</i>	0	<i>Ksed_amm</i>	25
<i>oxy_max</i>	500	<i>Fsed_nit</i>	-20
<i>amm_initial</i>	8	<i>Ksed_nit</i>	100
<i>nit_initial</i>	15	<i>theta_sed_amm</i>	1.08
<i>Rnitrif</i>	0.5	<i>theta_sed_nit</i>	1.08
<i>Knitrif</i>	78.1	<i>frp_initial</i>	2
<i>theta_nitrif</i>	1.08	<i>Fsed_frp</i>	0.2
<i>Rdenit</i>	0.1	<i>Ksed_frp</i>	50
<i>Kdenit</i>	1.8	<i>theta_sed_frp</i>	1.08

Tabela 6

Parâmetros de configuração do modelo AED2.

as séries sintéticas de fósforo total. Uma das estações de qualidade utilizadas - PARP 02100 - possui valores aproximadamente duas vezes mais altos do que as demais estações. Isso acarretou em um aumento da média da série histórica, causando também o aumento nas concentrações de entrada no reservatório.

Excluindo a modelagem do fósforo total, o modelo calibrado conseguiu representar razoavelmente os comportamentos médios do sistema, principalmente quando observados os gráficos da figura 15, que mostram a grande variação no espaço e tempo das medições de fósforo total e nitrato.

Terminada a calibração foi feita a modelagem do reservatório para os anos entre 1990 e 2018. A figura 16 apresenta os resultados da modelagem em forma de mapas de calor para os parâmetros de temperatura, OD, NO₃, NH₃ e PT do reservatório.

A partir da modelagem pode-se observar que o reservatório apresenta períodos bem definidos de estratificação térmica forte e fraca, sendo que os parâmetros de qualidade seguem fortemente a distribuição dessa estratificação.

Resultados e Conclusões

Como uma das principais contribuições deste trabalho, podem-se destacar os métodos para geração de dados de entrada complementares com grandes intervalos de tempo; sendo utilizados apenas bancos de dados disponíveis publicamente. Foi possível gerar séries de temperatura da água afluyente e qualidade da água de forma simples e satisfatória, já que a primeira obteve correlações consistentes com os dados observados, enquanto que a segunda mantém as propriedades estatísticas das séries.

Complementando essa geração de dados de entrada, foi possível desenvolver rotinas de execução em massa do modelo GLM; o que auxiliou na criação de métodos para a defi-




Figura 16. Mapas de calor resultantes da modelagem.

nição de períodos mínimos de aquecimento do modelo, análises de sensibilidades para dos parâmetros e também amparo para a geração de rotinas de auto calibração.

Diretamente sobre o reservatório da UHE Jurumirim, o modelo apresentou uma periodicidade evidente ao longo de todo o perfil de temperatura e oxigênio dissolvido. Essa estratificação ocorre durante o período de modelagem, sendo que entre os meses de novembro e abril a estratificação térmica e de oxigênio, para a média das camadas superfícies e de fundo, possui um delta aproximado de 5°C e 2.5 mg/l, e entre os meses de maio e outubro essa estratificação decresce para aproximadamente 2°C e 1.5 mg/l, respectivamente.

Para profundidade aproximadamente menores que 20 m a periodicidade sazonal de fósforo total, nitrato e nitrogênio amoniacal não pode ser percebida, porém nas regiões mais profundas que 20 m, a periodicidade, que antes só aparecia nos perfis de temperatura e oxigênio, começa a ser observada também nesses três parâmetros.

O modelo GLM possui ferramentas poderosas, sendo extremamente moldável a necessidade do modelador, tanto em quesitos de modelagem térmica, como de qualidade da água. Contudo existe a ressalva de que a curva de aprendizagem do modelo ainda é exponencial, dificultando a entrada de novos usuários e expansão rápida do modelo. As principais dificuldades estão na falta de interface gráfica do modelo, a não sincronização entre a sua documentação e versão e a quantidade de exemplos é baixa quando comparado com a quantidade de layouts possíveis. Essas dificuldades são esperadas de modelos colaborativos e de código aberto, sendo que com o aumento da comunidade e popularização do modelo, esses problemas logo devem ser resolvidos.

Referências

- AEMON. (2020). *Aquatic ecosystem modelling network*. Retrieved from <https://sites.google.com/site/aquaticmodelling/home>
- ANA. (2019). *Agência nacional de Águas*. Retrieved from <https://www.ana.gov.br/> (Acessado em 02/2019)
- Bernardo, J. W. Y. (2018). *Linking water quality issues with residence time and dimensionless numbers in reservoir* (Unpublished doctoral dissertation). Universidade Federal do Paraná, <https://acervodigital.ufpr.br/handle/1884/58929>.
- Bruce, L. C., Frassl, M. A., Arhonditsis, G. B., Gal, G., Hamilton, D. P., Hanson, P. C., ... others (2018). A multi-lake comparative analysis of the general lake model (glm): Stress-testing across a global observatory network. *Environmental modelling & software*, 102, 274–291.
- Bruggeman, J., & Bolding, K. (2014). A general framework for aquatic biogeochemical models. *Environmental modelling & software*, 61, 249–265.
- Chapin, T. P. (2015). High-frequency, long-duration water sampling in acid mine drainage studies: A short review of current methods and recent advances in automated water samplers. *Applied Geochemistry*, 59, 118–124.
- Colombo, G. T. (2019). *Dinâmica térmica em rios e relações com variáveis meteorológicas* (Unpublished master's thesis). Universidade Federal do Paraná, <https://acervodigital.ufpr.br/handle/1884/63819>.
- de Assis Esteves, F. (1998). *Fundamentos de limnologia*. Interciência.
- Facchi, A., Gandolfi, C., & Whelan, M. (2007). A comparison of river water quality sampling methodologies under highly variable load conditions. *Chemosphere*, 66(4), 746–756.
- Fenocchi, A., Rogora, M., Morabito, G., Marchetto, A., Sibilla, S., & Dresti, C. (2019). Applicability of a one-dimensional coupled ecological-hydrodynamic numerical model to future projections in a very deep large lake (lake maggiore, northern italy/southern switzerland). *Ecological Modelling*, 392, 38–51.
- Ferreira, D. M. (2019). *Integrated analysis for modeling of flow and transport of contaminants in rivers* (Unpublished doctoral dissertation). Universidade Federal do Paraná, <https://acervodigital.ufpr.br/handle/1884/61204>.
- Ferreira, D. M., Fernandes, C. V. S., Kaviski, E., & Fontane, D. (2019). Water quality modelling under unsteady state analysis: Strategies for planning and management. *Journal of environmental management*, 239, 150–158.
- GLEON. (2020). *Global lake ecological observatory network, disponível em https://gleon.org/*.
- Gomide, F. L. S. (2012). *Sobre reservatórios e segurança hídrica* (Tech. Rep.). GMD, Organização Industrial e Engenharia.
- Hipsey, M. R., Bruce, L. C., Boon, C., Busch, B., Carey, C. C., Hamilton, D. P., ... others (2019). A general lake model (glm 3.0) for linking with high-frequency sensor data from the global lake ecological observatory network (gleon). *Geoscientific Model Development*, 12(1), 473–523.
- Jia, X., Willard, J., Karpatne, A., Read, J., Zwart, J., Steinbach, M., & Kumar, V. (2019). Physics guided rnns for modeling dynamical systems: A case study in simulating lake temperature profiles. In *Proceedings of the 2019 siam international conference on data mining* (pp. 558–566).
- Kozak, C. (2016). *Water quality assessment and its effects on diffuse pollution considering a new water quality and quantity approach* (Master's thesis, Universidade Federal do Paraná). Retrieved from <https://www.acervodigital.ufpr.br/handle/1884/43629>
- Luckner, M. Y. A. (2018). *Análise da variação temporal do iqar utilizando o modelo cequal-w2: Proposta de um indicados com alta resolução temporal*.
- Moraetis, D., Efstathiou, D., Stamati, F., Tzoraki, O., Nikolaidis, N. P., Schnoor, J. L., & Vozinakis, K. (2010). High-frequency monitoring for the identification of hydrological and bio-geochemical processes in a mediterranean river basin. *Journal of Hydrology*, 389(1-2), 127–136.
- Orlob, G. T. (1983). *Mathematical modeling of water quality: Streams, lakes and reservoirs* (Vol. 12). John Wiley & Sons.
- Prats, J., Reynaud, N., & Danis, P. (2018). Application of the general lake model (glm) to a large set of french water bodies. In *5th iahr europe congress "new challenges in hydraulic research and engineering"* (pp. 337–338).
- Read, J. S., Hamilton, D. P., Jones, I. D., Muraoka, K., Winslow, L. A., Kroiss, R., ... Gaiser, E. (2011). Derivation of lake mixing and stratification indices from high-resolution lake buoy data. *Environmental Modelling & Software*, 26(11), 1325–1336.
- Read, J. S., Winslow, L. A., Hansen, G. J., Van Den Hoek, J., Hanson, P. C., Bruce, L. C., & Markfort, C. D. (2014). Simulating 2368 temperate lakes reveals weak coherence in stratification phenology. *Ecological Modelling*, 291, 142–150.
- Saha, S., Moorthi, S., Pan, H.-L., Wu, X., Wang, J., Nadiga, S., ... Goldberg, M. (2010). *Ncep climate forecast system reanalysis (cfsr) 6-hourly products, january 1979 to december 2010*. Boulder CO: Research Data Archive at the National Center for Atmospheric Research, Computational and Information Systems Laboratory. Retrieved from <https://doi.org/10.5065/D69K487J>
- Saha, S., Moorthi, S., Wu, X., Wang, J., Nadiga, S., Tripp, P., ... Becker, E. (2011). *Ncep climate forecast system version 2 (cfsv2) 6-hourly products*. Boulder CO: Research Data Archive at the National Center for Atmospheric Research, Computational and Information Systems Laboratory. Retrieved from <https://doi.org/10.5065/D61C1TXF>

Cenários e Compilação - Artigo 2

Matrizes de Transição como Ferramenta de Análise e Previsão da Qualidade da Água em Reservatórios

João Marcos Carvalho
Orientado

Tobias Bleninger
Orientador

Introdução

Reservatórios de forma geral são sistemas fundamentais para o desenvolvimento da sociedade, já que aumentam a garantia de um determinado recurso, facilitando a sua gestão frente às variabilidades naturais. No caso de reservatórios de água, a capacidade de garantir um determinado abastecimento, ou seja a chance de que eles venham a falhar durante a sua operação, está relacionada ao percentual da vazão média de longo termo que eles conseguem regularizar, a variância de vazões da região e com o volume do reservatório.

Dois dos vários métodos para a determinação da capacidade de regularização e tamanho de um reservatório são os de Moran (1954) e Gomide (1975). Ambos possuem bases e simplificações semelhantes, e podem ser resumidos da seguinte forma: A chance de um reservatório qualquer falhar ("secar") depende de três fatores - a vazão que ele precisa regularizar na sua saída, a distribuição de probabilidades das vazões que entram nele e o volume do reservatório. Como ambos considerando a vazão afluência como a única variável probabilística desse equacionamento, pode-se atribuir a probabilidade de ocorrência de uma determinada vazão de entrada, como sendo a mesma probabilidade da resposta do reservatório a essa vazão. Através dessas hipóteses é possível utilizar n vazões e n cenários de volume, de modo a permitir uma visão do comportamento geral do sistema. Ao organizar esses n cenários e as suas probabilidades de forma matricial, obtém-se uma matriz que pode indicar a probabilidade de que o reservatório esteja com um volume i e transite para um volume j , sendo essa a matriz de transição de estados de volume do reservatório. A figura 1 exemplifica esse processo de preenchimento de uma matriz de transição.

Mesmo com os seus grandes benefícios, a implementação de reservatórios de médio e grande porte, provocam mudanças drásticas nas velocidades desse novo sistema, alterando desse modo o comportamento físico e químico do corpo hídrico (de Assis Esteves, 1998), e adicionando mais importância para a variação espacial dentro deles. Com isso, a avaliação, monitoramento e previsão da qualidade da água, após a construção de um reservatório, se torna um processo difícil, longo e oneroso (Chou et al., 2018).

Como meio de solucionar essas dificuldades, modelos são usados a fim de representar esses sistemas; sendo eles baseados tanto em equações físicas quanto em ajustes mate-

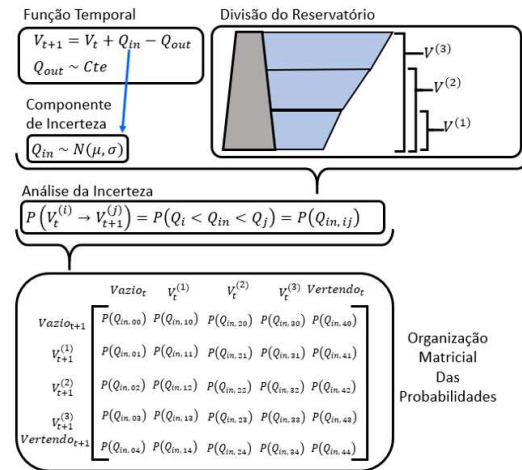


Figura 1. Esquema didático da análise de Moran (1954) e Gomide (1975) usando matrizes de transição.

máticos e estatísticos. Atualmente com o avanço da ciência de dados, muitos dos novos métodos de previsão se baseiam em técnicas de aprendizado de máquina, (Tung et al., 2020), tanto de forma exclusiva, (Chen et al., 2018), (Barzegar et al., 2018), (Arefinia et al., 2020), (Elkiran et al., 2019) e (Ahmed et al., 2019), como acoplados a modelos com embasamentos físicos (Jia et al., 2019). Contudo o grande problema desse tipo de vertente é a quantidade de dados disponíveis, já que nesse tipo de aplicação é necessário uma grande quantidade de informação bem distribuída em classes balanceadas para a devida calibração e validação do método (Erichson et al., 2019), sendo que quando utilizados para previsão essa necessidade é ainda maior (Callaham et al., 2019).

Não só em recursos hídricos os dados são poucos, como também não necessariamente são bem distribuídos de modo a representar adequadamente os principais processos envolvidos, (Chapin, 2015), (Kozak, 2016) e (Ferreira et al., 2019). Como exemplo, é comum que métodos de amostragem convencionais de qualidade da água subamostrem eventos extremos, pois existe um risco de segurança grande envolvido para uma equipe fazer coletas durante esses eventos. Algumas outras técnicas como a utilização de imagens de satélites e sensoriamento vem ajudando a diminuir essa limitação de banco de dados, porém ela ainda é recorrente no tema de qualidade da água em todo o globo, (Damania et al., 2019).

Com esse tipo de limitação amostral em mente, o trabalho em questão tem como objetivo estabelecer um método que possibilite o entendimento das incertezas de um sistema e também uma razoável capacidade de previsão do seu comportamento, sem que seja necessária uma grande quantidade de dados sobre o objeto de estudo.

Para isso foi feita uma adaptação dos métodos de Moran (1954) e Gomide (1975), tornando possível a utilização de modelos matemáticos complexos para a criação de matrizes de transição. Através dessa metodologia adaptada foi realizado um estudo de caso da avaliação da qualidade da água do reservatório da usina hidrelétrica Jurumirim, onde foi possível criar uma matriz de transição que leve em conta as incertezas e os dinamismo dentro desse sistema, através do uso de cenários e do modelo General Lake Model (GLM). Desse modo, estabelecendo um método capaz de ajudar na gestão e tomada de decisão sobre as condições em que um reservatório pode se encontrar no futuro, levando em consideração as incertezas dos processos naturais que o afetam.

Materiais e Métodos

Matriz de Transição de Estados

A matriz de transição tem como objetivo descrever uma cadeia de markov de forma visual e agrupada, onde normalmente as colunas da matriz representam os possíveis estados iniciais, e as linhas os possíveis estados finais de um sistema. Os métodos analíticos matriciais são populares como ferramentas de modelagem, pois oferecem a capacidade de construir e analisar, de maneira unificada, uma ampla classe de modelos estocásticos, (Latouche & Ramaswami, 1999).

Com esse tipo de configuração, a soma de cada coluna da matriz deve possuir valor igual a 1, pois todas as possibilidades do sistema devem constar na matriz, logo não existindo a possibilidade de transição para além dos estados utilizados nela. A figura 2 exemplifica como é feita uma matriz de transição usando o seguinte exemplo: Considerando que a chance de ocorrer um bloom de algas em um reservatório em um ano qualquer é de 20%, e que essa ocorrência pode ser considerada como estatisticamente independente ano a ano; o comportamento do reservatório frente esse fenômeno pode ser descrito utilizando uma matriz de transição. Como um bloom de algas é uma situação de alto risco do ponto de vista de gestão, uma única ocorrência será vista como uma falha total da gestão. Para isso na matriz considera-se que na ocorrência de um bloom a probabilidade do sistema se manter com o bloom é de 100%.

De modo geral a montagem de uma matriz de transição de estados, são necessários os seguintes itens:

1. Definir os Estados do Sistema:

É o mais facilmente cumprido, pois basta determinar um critério conforme a necessidade do entendimento

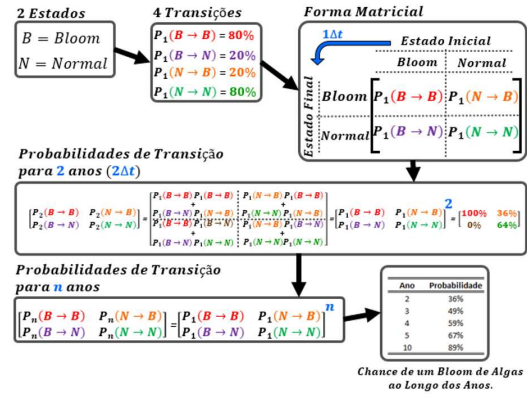


Figura 2. Exemplo didático das criação e propriedades de uma matriz de transição.

das variações do sistema, como por exemplo a CO-NAMA 357/2005, que classifica a qualidade da água de corpos hídricos no Brasil, ou uma lista de intervalos da variável a serem estudados. (No exemplo da figura 2 definiu-se dois estados: Normal ou Bloom).

2. Cálculo das Probabilidades de Transição de cada Estado:


Vários métodos podem ser utilizados nessa etapa, contudo quanto maior o número variáveis que regem a transição de estados, mais complexo se torna a sua determinação. (No exemplo da figura 2 o equacionamento é dado diretamente pelas probabilidades de ocorrer ou não o bloom de algas).

3. Sistema com Memória Markoviana:

O estado futuro do sistema deve depender apenas do estado anterior a ele. (No exemplo da figura 2 esse processo ocorre, pois supõem-se que os eventos são estatisticamente independentes).

Neste trabalho os estados do sistema são intervalos discretos das variáveis avaliadas na modelagem da qualidade da água, enquanto que as probabilidades são obtidas pela análise estatística das entradas do modelo. As variáveis de entrada foram consideradas estatisticamente independentes, fazendo com que a probabilidade de transição seja a multiplicação das probabilidade de cada variável de entrada do modelo, e cumprindo o último critério.

Para a determinação das probabilidades foi ajustada uma distribuição normal de probabilidades para as médias anuais de cada variável de entrada do modelo. As distribuições foram então discretizadas em intervalos, de modo que a probabilidade de ocorrência de um valor qualquer é considerada como sendo a probabilidade de ocorrência do intervalo em que ele se encontra. A figura 3 mostra esse processo de discretização e atribuição da probabilidade da distribuição normal nesse intervalo.



Sendo $FDA(X)$ = Função de Distribuição Acumulada
e $X_2 \leq X < X_3$

Logo, $P(X) = FDA(X_3) - FDA(X_2)$

Figura 3. Exemplo da atribuição de probabilidade para a matriz de transição.

Modelagem de Reservatórios

Moran (1954) na criação de seu método de dimensionamento, utiliza a equação do balanço de massa de água, equação 1, em conjunto com a distribuição de probabilidades das variáveis aleatórias, para montar a matriz com as probabilidades de transição de 1 intervalo de tempo. Dado que o processo é considerado markoviano, a multiplicação dessa matriz n vezes, fornece as probabilidades de transição para n intervalos de tempo. Através dessas hipóteses é possível prever a possibilidade de falha de um reservatório para n anos futuros.

$$V_{t+1} = V_t + (Q_t - R_t)$$

onde,

$$V_t = \text{Volume no tempo } t \quad (1)$$

$$R_t = \text{Vazão regularizada (constante)}$$

$$Q_t = \text{Vazão Afluente} \sim N(\mu, \sigma)$$

Esse tipo de abordagem só é possível devido a disponibilidade de uma equação, ou sistema de equações, que sejam razoavelmente fáceis de resolver, tornando a sua aplicação limitada a sistemas mais simplificados. Por isso essa estratégia apresenta limitações quando aplicada em modelos computacionais, já que o algebrismo necessário para o seu desenvolvimento é muitas vezes impraticável.

Como o uso de modelos computacionais é muitas vezes necessário para representar o comportamento da qualidade da água de reservatórios, uma alternativa foi proposta a fim de contornar essa condição limitante. Para sanar a falta de equações robustas e simples, capazes de serem analisadas sem a utilização de métodos numéricos, foi adotado o uso de cenários considerados representativos de um intervalo de comportamentos.

Os cenários foram gerados através de uma análise estatística das entradas do modelo, de modo que cada cenário possui um probabilidade atrelada a ele. Executando esses cenários dentro do modelo computacional, obtém-se estados iniciais e finais que estão atrelados à probabilidade de ocorrência do cenário. Com isso é possível obter as probabilidades de transição de um estado inicial e final, e com uma quantidade suficiente de cenário, organizar os resultados desses cenários em uma matriz de transição.

Como ferramenta de modelagem adotou-se o General Lake Model (GLM), sendo ele capaz de representar um reservatório de forma verticalmente unidimensional (Hipsey et al., 2019). Esse modelo foi adotado, pois como mostrado por Carvalho (2020), o reservatório da UHE Jurumirim possui uma estratificação térmica e química, tornando interessante uma análise individualizada das partes estratificadas da coluna d'água do sistema.

As informações utilizadas para a sua modelagem foram as de qualidade da água e morfologia, dados fluviométricos e dados meteorológicos, sendo eles extraídos das seguintes fontes respectivamente: ANA (2019), operador do reservatório (CTG-Brasil) e modelo meteorológico de reanálise CFSR, (Saha et al., 2010) e (Saha et al., 2011). A figura 4 apresenta o reservatório em si, junto com os pontos geográficos das séries temporais que serão utilizadas para a sua modelagem.

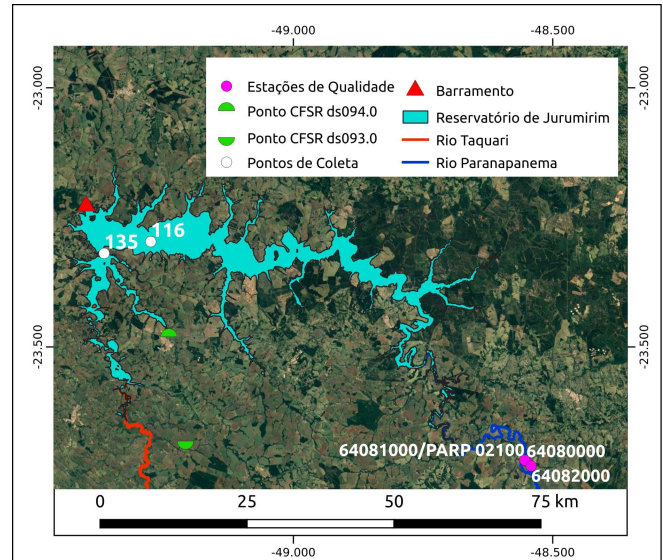


Figura 4. Posicionamento do reservatório, das estações de monitoramento e pontos de medição utilizados.

A quantidade de informações de entrada que o modelo pode absorver é elevada e pode ser vista pelo desenho didático da figura 5, entretanto dado a sua maleabilidade, nem todos esses dados são essenciais, dependendo apenas do grau de complexidade requisitado por cada projeto. Dado a flexibilidade do modelo, optou-se por utilizar as considerações

feitas por Carvalho (2020), de modo que as variáveis que regem o modelo são apresentadas na tabela 1.




Figura 5. Esquema didático com os parâmetros necessários para o modelo, fonte (Carvalho, 2020).

A vazão defluente e nível inicial, serão tratadas de modo a sempre serem modeladas com a sua respectiva vazão afluente, assim como a temperatura da água afluente com a temperatura do ar. Esse tipo de agrupamento foi adotado para evitar incoerências durante a criação dos cenários de modelagem, já que as variáveis dentro desses dois grupos são diretamente dependentes.

Distribuição de Probabilidades e Independência Estatística

As variáveis consideradas como aleatórias foram as de vazão, temperatura do ar, umidade relativa do ar e velocidade do vento. Devido a quantidade reduzida de dados, os parâmetros de qualidade da água não foram considerados como probabilísticos, sendo usado uma série temporal em escala diária com aproximadamente 1.5 ano de comprimento, gerada a partir de um modelo markoviano com as médias diárias observadas em campo, como descrito por Carvalho (2020).

Tabela 1

Fonte de cada dado utilizado.

Fonte	Variável
Dados da CTG Brasil	Vazão Afluente Vazão Defluente Nível Inicial
Modelo CFSR (ds0930.0 e ds0940.0)	Temperatura do Ar Umidade Relativa Velocidade do Vento
Estações de Qualidade 64080000 (hidroweb), 64081000 (hidroweb), 64082000 (hidroweb), e PARP 02100 (CETESB)	Temperatura da Água Afluente Oxigênio Dissolvido Fósforo Total Nitrato Nitrogênio Amoniacal

Ao todo foram ajustadas quatro distribuições normais de probabilidade, uma para cada variável considerada aleatória. A avaliação do ajuste da distribuição normal de probabilidades das variáveis foi feita através dos testes de Kolmogorov-Smirnov (KS), Anderson-Darling (AD) e Shapiro-Wilk (SW), com nível de significância de 5%. A tabela 2 apresenta os p-valores obtidos junto com a aceitação ou não aceitação da normalidade de cada série para os 3 testes, enquanto que a figura 6 contém uma compilação dos histogramas, com as distribuições de probabilidades ajustadas.

Foi também aplicado o teste de χ^2 para um nível de significância de 5%, com a finalidade de avaliar a independência estatística entre as quatro variáveis; tabela 3. Isso foi feito, pois comprovado a independência estatística entre elas, a probabilidade de ocorrência de um cenário gerado pela combinação dessas quatro variáveis, pode ser tomada como sendo o produto das probabilidades individuais de cada uma delas. Tal propriedade evita a necessidade de ajuste de uma distribuição de probabilidade conjunta das quatro variáveis, simplificando o processo.

Todas as variáveis foram aceitas em pelo menos 2 dos 3 testes de normalidade aplicados, logo a hipótese de normalidade foi considerada como aceita para todas elas. As quatro variáveis também foram consideradas independentes, se-

Tabela 2

Aceitação da hipótese de normalidade de cada variável e p-valor do teste.

Variável	KS	SW	D'A
Vazão	96%	67%	60%
Afluente	Sim	Sim	Sim
Tempetura do Ar	91%	76%	50%
Umidade	16%	4.6%	12%
Relativa	Sim	Não	Sim
Velocidade do Vento	77%	56%	24%
	Sim	Sim	Sim

Tabela 3

Relação de dependências entre as variáveis e p-valor do teste.

Variável	Vazão Afluente	Temp. Ar	Umi. Relativa	Velo. Vento
Vazão	0%	16%	49%	28%
Afluente	Depend.	Independ.	Independ.	Independ.
Temp.	16%	0%	17%	44%
Ar	Independ.	Depend.	Independ.	Independ.
Umi.	49%	17%	0%	34%
Relativa	Independ.	Independ.	Depend.	Independ.
Velo.	28%	44%	34%	0%
Vento	Independ.	Independ.	Independ.	Depend.

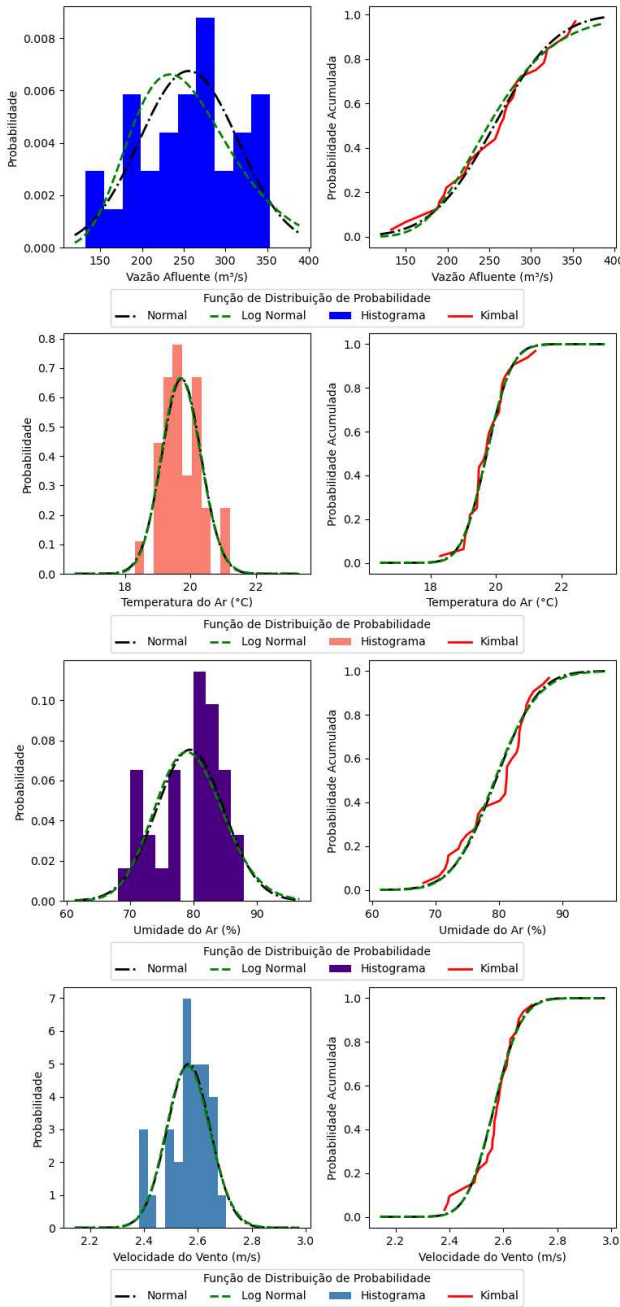


Figura 6. Histogramas e ajustes das distribuições normal, lognormal e empírica de Kimbal.

gundo o teste de χ^2 para um nível de significância de 5%.

A partir desses resultados estatísticos prévios, foram ajustadas distribuições normais individuais para cada uma das variáveis, sendo que essas distribuições serviram de base para a formulação dos cenários de modelagem e a inferência das probabilidades de transição utilizadas na criação da matriz de transição de estados.

Geração dos Modelos

Como não se pode avaliar uma equação explícita para esse tipo de problema, a modelagem de cenários foi utilizada como artifício para contornar isso. Os cenários foram criados a partir das séries observadas, sendo selecionadas séries que representem um determinado intervalo da distribuição de probabilidade ajustada de cada parâmetro.

A configuração dos parâmetros do modelo GLM foi a mesma que a utilizada por (Carvalho, 2020), usando desse modo um modelo previamente calibrado.

As séries de dados utilizadas foram selecionadas, a partir de intervalos definidos dentro de cada distribuição normal ajustada. Os intervalos foram feitos do seguinte modo: Definindo-se um número n de intervalos, $n - 1$ pontos equidistantes no eixo x da distribuição de probabilidades são estimados, sendo que esses pontos definem os limites de cada intervalo. Neste trabalho foi utilizado um n igual a 10, sendo que como a distribuição normal está contida entre $-\infty$ e ∞ , o primeiro e último pontos traçados foram forçados como sendo os pontos onde a distribuição acumulada de probabilidades é igual a 1% e 99%. Para o n definido 10 séries foram escolhidas para cada um dos 4 parâmetros, gerando 10000 modelos, resultantes da combinação entre as séries. As séries temporais foram utilizadas em escala diária com aproximadamente 1.5 anos de comprimento, de modo a contemplar os meses de aquecimento e o 1 ano e 1 mês de modelagem entre janeiros consecutivos.

Além disso, como hipótese simplificadora, cada intervalo foi associado a uma série de dados observados, sendo essa série considerada representativa de todo ele. Para a escolha dessa série, foram selecionadas as que possuem a sua média anual mais próxima do centro de cada intervalo. Neste processo não necessariamente todos os intervalos podem vir a possuir dados observados, sendo que caso um intervalo não possuir nenhuma série medida, a série mais próxima do centro do intervalo é escolhida e também ajustada por um fator de correção, a fim de criar uma série que se encontre nesse intervalo. O fator de correção é originado pela divisão do centro do intervalo pela média da série escolhida, desse modo a média da nova série é obrigatoriamente o valor central do intervalo.

A figura 7 apresenta os 10 intervalos definidos para cada distribuição normal e a posição da média das séries selecionadas, sendo também informado se foi ou não aplicado um fator de ponderação na série, para o caso de não existência de dados amostrais dentro do respectivo intervalo.

Compilação

Para o arranjo final dos dados e montagem da matriz, foi feita a compilação dos resultados dos modelos, junto com as análises estatísticas das séries que geraram cada um deles.

Cada modelo possui um valor inicial e final da variável

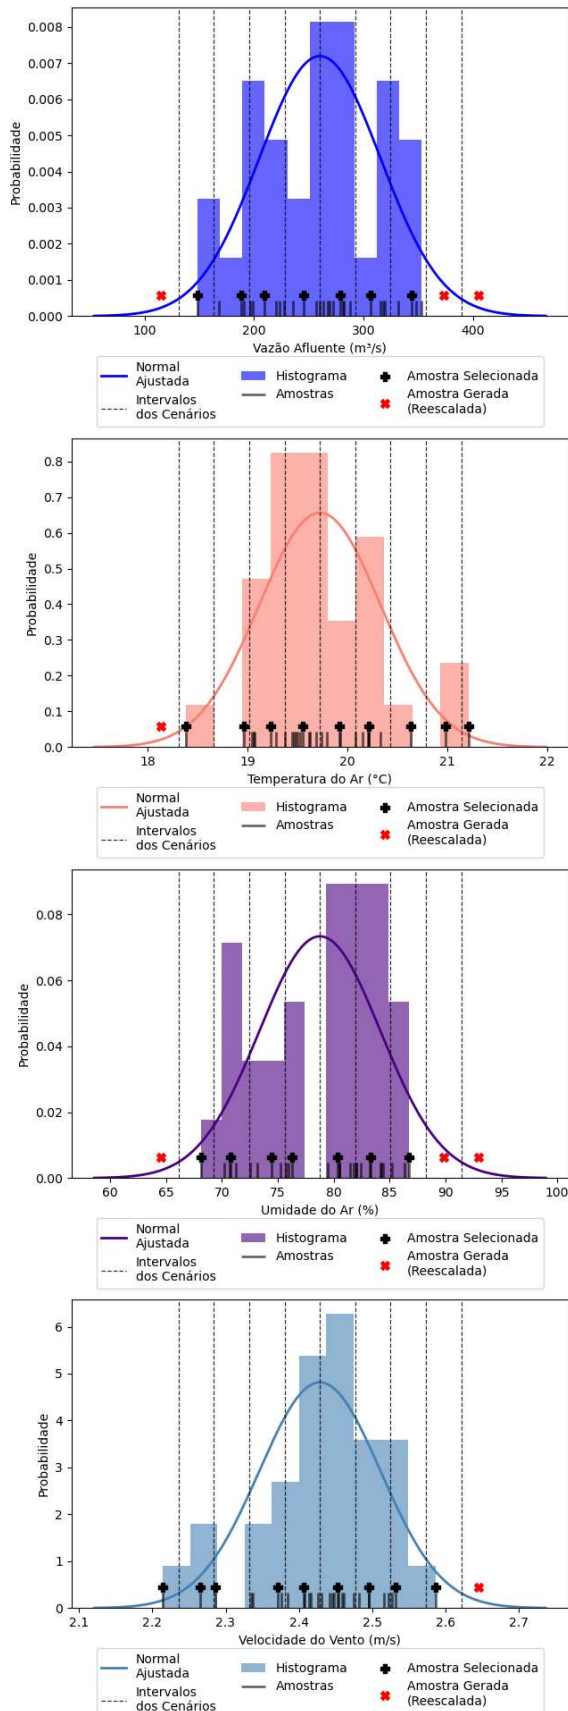


Figura 7. Normal ajustada com os 10 intervalos para a criação dos cenários e a média da série selecionada como representativa do intervalo.

analisada, desse modo já existindo a sua posição dentro da grade da matriz de transição. Com a finalidade de amortecer possíveis extremos e tornar a matriz mais utilizável, do ponto de vista da gestão de reservatórios, o estado inicial e final de cada variável foi considerado como sendo a média do mês de janeiro inicial e final de cada cenário. Deste modo um único *outlier* não é capaz de distorcer o posicionamento de um cenário dentro da matriz, além de prover uma resolução temporal mais interessante para a gestão do sistema.

A probabilidade de cada cenário foi obtida através do produto das probabilidades das séries das variáveis que o cenário em questão. Lembrando que cada uma das séries representa um intervalo de probabilidades dentro da distribuição normal de probabilidades de vazões, temperatura do ar, velocidade do vento e umidade relativa do ar.

Com as informações de estado inicial, final e probabilidade é possível montar a matriz de transição, pois os estados representam as coordenadas dentro da matriz, enquanto que a probabilidade faz o preenchimento das células da matriz. Caso dois ou mais modelos apresentem as mesmas coordenadas dentro da matriz (estado inicial e final), a probabilidade de ocorrência daquela coordenada é tida como a soma das probabilidades desses modelos.

Como o reservatório da UHE Jurumirim apresenta estratificação térmica e química, a análise dos resultados do reservatório foram divididas em 3 partes, terço superior, médio e inferior, além de também ser analisada a média do perfil todo.

Resultados

Matriz Geral

A partir das informações de estado inicial, final e probabilidade de cada cenário, foi feita a organização desses dados de forma matricial com intervalos discretos. As colunas da matriz apresentam os possíveis estados iniciais e as linhas os possíveis estados finais do reservatório, desse modo permitindo o posicionamentos das probabilidades de transição dentro da matriz.

A figura 8 apresenta o resultado desse processo para a temperatura da água do reservatório. Como exemplo de interpretação: A probabilidade de que o reservatório esteja com uma temperatura dentro do intervalo (27°C, 28°C] e depois entre (28°C, 29°C] em dois janeiros consecutivos é de 12%.

A matriz da figura 8 não é propriamente uma matriz de transição, sendo necessária a realização de um processo de marginalização de cada uma das colunas para que ela se transforme nesse tipo de matriz. O processo de marginalização consistiu na normalização de cada probabilidade pela soma da coluna em que ela se encontra. A figura 9 apresenta o resultado desse processo de marginalização, sendo que nesse caso a sua interpretação deve ser feita do seguinte

modo: Dado que a temperatura inicial do sistema se encontra dentro do intervalo (27°C, 28°C], a probabilidade de que ela transite para o intervalo (28°C, 29°C] é de 28%.

Como a apresentação de todas as matrizes de transição geradas se tornaria repetitivo devido ao grande número de parâmetros e a divisão do reservatório em três seções, alguns casos foram selecionados como mais interessantes para análise.

Na figura 10 se encontram as matrizes de transição para oxigênio dissolvido, sendo apresentado as divisões em terços - superfície, meio e fundo - dado que esse parâmetro é bastante estratificado no reservatório. A opção por esse parâmetro se deu, pois apresenta estratificação semelhante a estratificação térmica, representando então o comportamento geral de ambos parâmetros na matriz.

Como esperado, nota-se nas matrizes o decaimento da taxa de oxigênio dissolvido ao longo da coluna d'água. Nas camadas de superfície e meio a estabilidade do sistema é




Figura 8. Matriz de probabilidades - Temperatura média do perfil.




Figura 9. Matriz de transição - Temperatura média do perfil.




Figura 10. Matrizes de transição (perfil vertical dividido em 3 terços de mesma altura)- Oxigênio Dissolvido.

maior que a do fundo, pois apresenta uma menor capacidade de transitar entre intervalos maiores que 1 estado, sendo que a superfície tem uma tendência maior a estar com concentrações entre 7.5 e 8 mg/l, enquanto o meio entre 7 e 7.5 mg/l.

Os resultados para nitrato, nitrogênio amoniacal e fósforo total se encontram nas figuras 11, 12 e 13, sendo apresentadas as matrizes de transição para as médias dos perfis e terço

inferior do reservatório. Optou-se por mostrar esses resultados, pois esses parâmetros apresentam perfis médios relativamente estáveis, apresentando maiores variações apenas no fundo do reservatório, devido às interações com o sedimento.

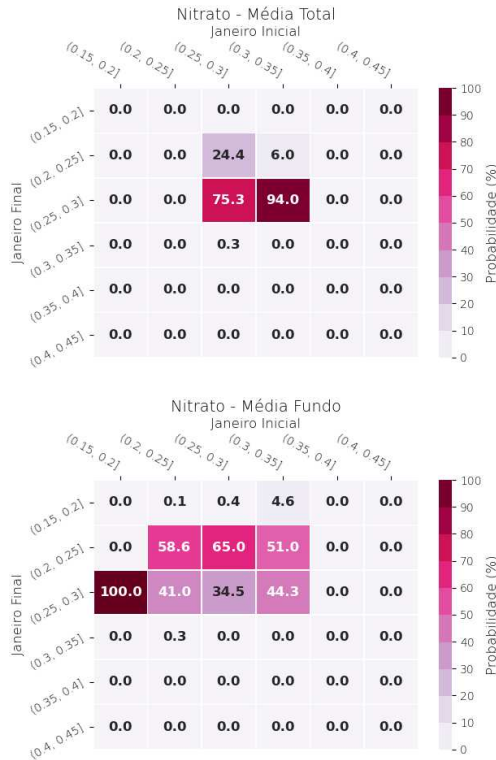


Figura 11. Matrizes de transição do perfil todo e do terço inferior do perfil - Nitrato.

Todos os 3 parâmetros apresentam uma variabilidade muito mais acentuada na região mais profunda do sistema, sendo que em comparação com a média do perfil, o número de estados possíveis dobra de 2 para 4.

Matriz Censurada

As matrizes até aqui apresentadas fornecem a informação global do sistema, porém outra vantagem dessa abordagem é o ganho de assertividade que suposições a priori podem fornecer ao seu entendimento. Como exemplo, foram analisados apenas os cenários onde a vazão média anual foi maior que $250 \text{ m}^3/\text{s}$ e umidade relativa superior a 80%. Com esses dois critérios pode-se entender melhor os possíveis comportamentos do sistema durante um período mais específico. Deste modo foram separados apenas os cenários que atendem essas duas condições, totalizando 2000 cenários.

A figura 14 apresenta a comparação entre as matrizes de transição completa e censurada de oxigênio dissolvido para a média do perfil de janeiro.




Figura 12. Matrizes de transição do perfil todo e do terço inferior do perfil - Nitrogênio Amoniacoal.

Nota-se que tendo um conhecimento a priori do comportamento futuro do sistema, as possibilidades a serem consideradas são estreitadas. Usando como exemplo a figura 14, observa-se que para os dois critérios adotados, já não é mais preciso levar em consideração eventos onde o oxigênio dissolvido do sistema possa se tornar inferior a 6.5 mg/l . Esse tipo de análise é útil para processos de tomada de decisões e ações, já que permite uma análise mais precisa das incertezas do sistema.

Validação Simplificada

Uma das desvantagens do método apresentado até agora é a dificuldade que se tem de validar os resultados obtidos, já que um dos propósitos dele é o de sanar a falta de informação de uma variável que é capaz de ser modelada matematicamente.

Como não existem dados medidos de janeiros consecutivos da qualidade da água do reservatório da UHE Jurumirim, optou-se por utilizar os valores modelados por Carvalho (2020) com intervalo diário entre 01/1990 e 01/2019, obtendo assim 29 pares de dados que indicam as transições que ocorreram no reservatório. Desse modo é possível ao menos identificar se as simplificações adotadas dentro do modelo, como o tempo de aquecimento e a utilização de séries que



Figura 13. Matriz de transição do perfil todo e do terço inferior do perfil - Fósforo Total.

representam um determinado intervalo podem ser aceitas.

Para essa validação simplificada do modelo foi plotado junto com a matriz de probabilidades de cada parâmetro, os pares de dados de dois janeiros consecutivos do modelo de 01/1990 até 01/2019. Desse modo, caso as transições observadas no modelo contínuo sejam semelhantes aos da matriz de probabilidade, o modelo pode ser considerado como suficientemente representativo.

A figura 15 apresenta esses gráficos, sendo que apenas para a matriz de fósforo total pode-se observar um leve deslocamento dos pares de pontos do modelados, aproximadamente 0.05 mg/l de deslocamento. Isso pode ter ocorrido devido a um tempo de aquecimento insuficiente do modelo, já que o fósforo total foi o parâmetro que mais demorou para convergir durante os testes de aquecimento do método. Contudo os resultados gerais ainda se mostram satisfatórios.

Matriz Multiplicada

Outra capacidade desse tipo de abordagem é o artifício onde, dado que o sistema não possui autocorrelação de nenhum grau na escala temporal, é possível elevar a matriz de transição por um número qualquer n , de modo que o intervalo de tempo da transição é igual a n . Por exemplo, todas as matrizes mostradas são limitadas ao intervalo de tempo de 1




Figura 14. Matriz de transição completa (acima) e censurada (abaixo) - Oxigênio Dissolvido média no perfil.

ano, ou seja, n é igual a 1. Essa propriedade multiplicativa aumenta mais a sua capacidade de auxiliar no entendimento do sistema, já que também pode ser utilizada para o seu entendimento ao longo de diversos anos. Vale lembrar que para sistemas não caóticos como esse, a partir de um certo valor de n a matriz se estabiliza, ou seja as suas probabilidades são as mesmas para qualquer valor de n maior ou igual ao de estabilização.

Para a matriz de transição possuir essa propriedade é necessário a verificação da não autocorrelação entre anos consecutivos, pois desse modo os anos podem ser considerados independentes e também as suas probabilidades de ocorrência.

Para cumprir esse critério foi plotada a função de autocorrelação (FAC) para os 5 parâmetros, sendo elas apresentadas na figura 16. Através dos 5 gráficos é possível identificar que a hipótese de não autocorrelação pode ser aceita para todos os parâmetros; possibilitando a utilização do processo multiplicativo nas matrizes.

A figura 17 mostra esse processo para a matriz de transição da média do perfil de temperaturas. O tempo de conver-




Figura 15. Matrizes de probabilidade junto com os pares de janeiros consecutivos modelados.

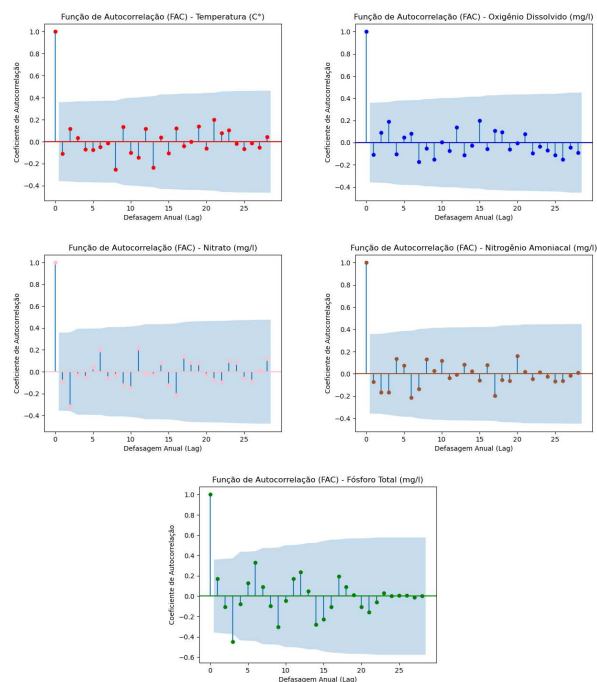


Figura 16. Funções de autocorrelação dos parâmetros de qualidade.

gência do processo multiplicativo das matrizes foi aproximadamente o mesmo para todos os parâmetros, variando entre 7 e 9 multiplicações.

Esse procedimento também pode ser estendido para as matrizes censuradas, porém com ressalvas, dado que uma diminuição no número de cenário pode gerar matrizes de transição com descontinuidades, fazendo com que a sua multiplicação convirja para zero. Na figura 18 pode-se observar um exemplo desse fenômeno, onde na matriz de transição, existe uma descontinuidade na coluna de intervalo (25°C, 26°C] e linha de intervalo (27°C, 28°C]; por essa descontinuidade, quando elevada a n , a matriz tende a convergir para zero, não obtendo assim um resultado fidedigno com a realidade.

Exemplo de Aplicação

Como exemplo da aplicação da matriz de transição foi criado um cenário hipotético. Para isso foi utilizado novamente o modelo GLM aplicado por Carvalho (2020), para o período de 01/1990 a 01/2019, sendo feita a consideração de que os dados desse modelos são os observados em campo. A ideia do exemplo é se colocar no lugar do gestor do reservatório no início do ano de 1990, porém com a matriz de transição em mãos como ferramenta de gestão. O objetivo é utilizar a matriz como auxiliar no entendimento de como o reservatório pode se encontrar no próximo ano. Para isso foram utilizados os parâmetros de oxigênio dissolvido e temperatura no exemplo.











Figura 17. Matriz de transição iterada para n igual 2, 4, 6 e 8 anos - Temperatura média do perfil.

Figura 18. Matriz de transição iterada e censurada para n igual a 1, 5, 10 e 50 anos - Temperatura média do perfil.

A figura 19 contém um exemplo do meio de utilização proposto, onde para cada nova amostra, a matriz é consultada e as probabilidades dos próximos estados são inseridos dentro da série temporal. Para isso a matriz é consultada em cada novo janeiro (estado inicial), e a coluna da matriz referente ao intervalo que esse novo janeiro se encontra, é inserida dentro da série temporal, logo na frente do dado. Assim facilitando a análise contínua das chances do sistema transitar para cada estado futuro.

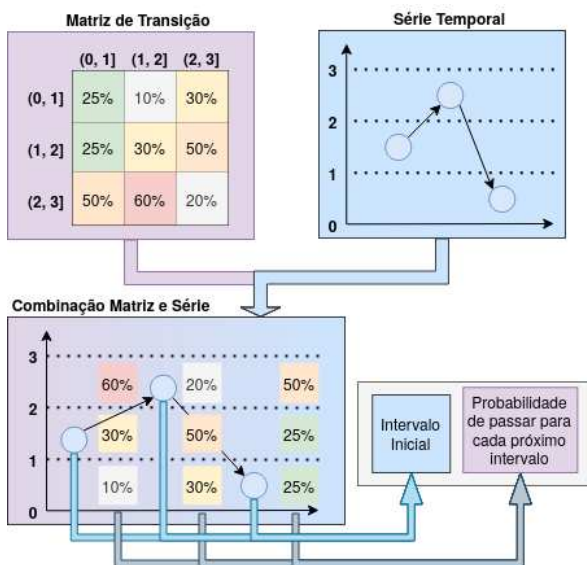


Figura 19. Exemplo de interpretação da matriz de transição em conjunto com uma série temporal de dados.

Foram montados quatro gráficos seguindo esse modelo, dois deles considerando a matriz de transição geral de temperatura e oxigênio, já apresentada nas figuras 9 e 10, respectivamente. Os resultados dessa análise se encontram na figura 20.

Pelo exemplo de aplicação é possível observar que a matriz consegue fornecer uma informação razoável do comportamento futuro do reservatório, sendo que na maior parte dos passos temporais o intervalo de maior probabilidade de ocorrência também foi o ocorrido. Notou-se que em períodos onde a probabilidade é mais igualmente distribuída entre os intervalos, a frequência em que o intervalo de maior probabilidade é o mesmo do ocorrido diminui.

Os outros dois gráficos foram feitos com o mesmo princípio, porém foi utilizada a matriz censurada e individualizada para cada nova amostra na série temporal. A censura foi feita do seguinte modo:

- Separação das médias dos parâmetros de entrada do modelo do ano anterior.
- Identificação do intervalo em que cada um dos quatro parâmetros de entrada se encontram.

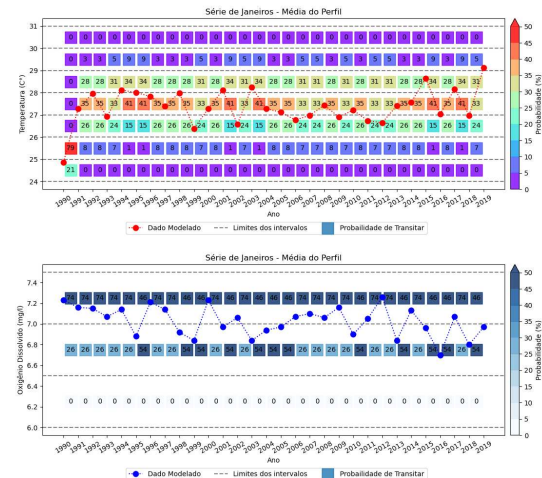


Figura 20. Série temporal com a matriz de transição acoplada - média do perfil

- Identificação do próximo intervalo abaixo e acima dos encontrados.
- Seleção de todos os cenários que dentro desse novo intervalo triplo.
- Geração da matriz com os cenários selecionados.
- Repetição do processo até a penúltima amostra.

A ideia por trás disso é melhorar o entendimento do sistema, usando como hipótese que os próximos eventos não serão muito diferentes dos que ocorreram no ano anterior. Desse modo usa-se a informação de 1989 para tentar melhor entender o processo de transição entre 1990 e 1991, e assim por diante até 2019. Os resultados completos desta abordagem se encontram na figura 21.

Os exemplos aplicados à matriz censurada obtiveram resultados semelhantes aos com a matriz não censurada. Esses resultados foram o contrário do que se esperava da matriz censurada, já que dados mais específicos tendem a melhorar os resultados obtidos. Isso pode ter ocorrido devido ao critério aplicado para fazer a censura da matriz, que pode não ter sido suficientemente bem definido para melhorar os resultados.

Como o processo de seleção de cenários para melhorar o processo de previsão não é o tema principal do trabalho, e sim um complemento de como a matriz de transição pode ser aplicada e moldada, mais detalhes sobre ele não serão discutidos. Contudo fica a oportunidade para trabalhos futuros que podem vir a explorar o melhor tipo de censura a ser aplicada para obter um previsões mais precisas.




Figura 21. Série temporal com a matriz de transição censurada acoplada - média do perfil

Conclusões

O método aqui apresentado é uma alternativa viável para representações matemáticas complexas de um determinado fenômeno, aumentando as possibilidades da utilização de matrizes de transição em diversos sistemas. Contudo ele possui limitações, como a necessidade de criação e execução de uma grande quantidade de cenários. A quantidade de cenários deve ser suficiente e bem balanceada, para que o método seja capaz de representar os possíveis comportamentos do sistema.

As probabilidades apresentadas nas matrizes podem parecer pouco precisas, contudo isso ocorre em grande quantidade, pois esse método tende a apresentar de forma mais explícita as incertezas inerentes aos processos naturais.

Como ressalva, vale lembrar que o método usa eventos já ocorridos para estimar o comportamento de um sistema; logo a sua utilização como ferramenta de previsão e gestão só é válida para sistemas estacionários. Caso contrário, a metodologia deve ser adaptada para corrigir e considerar os efeitos de não estacionariedades.

Mesmo com as suas limitações esse tipo de abordagem é vantajosa fornece uma ferramenta interessante para a operação e previsão de reservatórios, pois a matriz é de simples e intuitiva interpretação, que carrega uma grande quantidade de informação sobre um sistema e seus riscos.

Referências

- Ahmed, A. N., Othman, F. B., Afan, H. A., Ibrahim, R. K., Fai, C. M., Hossain, M. S., ... Elshafie, A. (2019). Machine learning methods for better water quality prediction. *Journal of Hydrology*, 578, 124084.
- ANA. (2019). *Agência nacional de Águas*. Retrieved from <https://www.ana.gov.br/> (Acessado em 02/2019)

Arefinia, A., Bozorg-Haddad, O., Oliazadeh, A., & Loáiciga, H. A. (2020). Reservoir water quality simulation with data mining models. *Environmental Monitoring and Assessment*, 192(7), 1–13.

Barzegar, R., Moghaddam, A. A., Adamowski, J., & Ozga-Zielinski, B. (2018). Multi-step water quality forecasting using a boosting ensemble multi-wavelet extreme learning machine model. *Stochastic environmental research and risk assessment*, 32(3), 799–813.

Callahan, J. L., Maeda, K., & Brunton, S. L. (2019). Robust flow reconstruction from limited measurements via sparse representation. *Physical Review Fluids*, 4(10), 103907.

Carvalho, J. M. (2020). Generalização da construção de modelos para reservatórios - estudo de caso uhe jurumirim.

Chapin, T. P. (2015). High-frequency, long-duration water sampling in acid mine drainage studies: A short review of current methods and recent advances in automated water samplers. *Applied Geochemistry*, 59, 118–124.

Chen, S., Fang, G., Huang, X., & Zhang, Y. (2018). Water quality prediction model of a water diversion project based on the improved artificial bee colony-backpropagation neural network. *Water*, 10(6), 806.

Chou, J.-S., Ho, C.-C., & Hoang, H.-S. (2018). Determining quality of water in reservoir using machine learning. *Ecological informatics*, 44, 57–75.

Damania, R., Desbureaux, S., Rodella, A.-S., Russ, J., & Zaveri, E. (2019). *Quality unknown: The invisible water crisis*. The World Bank.

de Assis Esteves, F. (1998). *Fundamentos de limnologia*. Interciência.

Elkiran, G., Nourani, V., & Abba, S. (2019). Multi-step ahead modelling of river water quality parameters using ensemble artificial intelligence-based approach. *Journal of Hydrology*, 577, 123962.

Erichson, N. B., Mathelin, L., Yao, Z., Brunton, S. L., Mahoney, M. W., & Kutz, J. N. (2019). Shallow learning for fluid flow reconstruction with limited sensors and limited data. *arXiv preprint arXiv:1902.07358*.

Ferreira, D. M., Fernandes, C. V. S., Kaviski, E., & Fontane, D. (2019). Water quality modelling under unsteady state analysis: Strategies for planning and management. *Journal of environmental management*, 239, 150–158.

Gomide, F. L. S. (1975). Range and deficit analysis using markov chains. *Hydrology papers (Colorado State University)*; no. 79.

Hipsey, M. R., Bruce, L. C., Boon, C., Busch, B., Carey, C. C., Hamilton, D. P., ... others (2019). A general lake model (glm 3.0) for linking with high-frequency sensor data from the global lake ecological observatory network (gleon). *Geoscientific Model Development*, 12(1), 473–523.

- Jia, X., Willard, J., Karpatne, A., Read, J., Zwart, J., Steinbach, M., & Kumar, V. (2019). Physics guided rnns for modeling dynamical systems: A case study in simulating lake temperature profiles. In *Proceedings of the 2019 siam international conference on data mining* (pp. 558–566).
- Kozak, C. (2016). *Water quality assessment and its effects on diffuse pollution considering a new water quality and quantity approach* (Master's thesis, Universidade Federal do Paraná). Retrieved from <https://www.acervodigital.ufpr.br/handle/1884/43629>
- Latouche, G., & Ramaswami, V. (1999). *Introduction to matrix analytic methods in stochastic modeling* (Vol. 5). Siam.
- Moran, P. (1954). A probability theory of dams and storage systems. *Aust. Jour. App. Sci.*, 5, 116–124.
- Saha, S., Moorthi, S., Pan, H.-L., Wu, X., Wang, J., Nadiga, S., ... Goldberg, M. (2010). *Ncep climate forecast system reanalysis (cfsr) 6-hourly products, january 1979 to december 2010*. Boulder CO: Research Data Archive at the National Center for Atmospheric Research, Computational and Information Systems Laboratory. Retrieved from <https://doi.org/10.5065/D69K487J>
- Saha, S., Moorthi, S., Wu, X., Wang, J., Nadiga, S., Tripp, P., ... Becker, E. (2011). *Ncep climate forecast system version 2 (cfsv2) 6-hourly products*. Boulder CO: Research Data Archive at the National Center for Atmospheric Research, Computational and Information Systems Laboratory. Retrieved from <https://doi.org/10.5065/D61C1TXF>
- Tung, T. M., Yaseen, Z. M., et al. (2020). A survey on river water quality modelling using artificial intelligence models: 2000–2020. *Journal of Hydrology*, 585, 124670.

CONCLUSÃO

O objetivo principal de desenvolver uma metodologia para a criação de uma matriz de transição da qualidade da água em reservatórios foi alcançado de maneira satisfatória, dado que os resultados apresentados para o estudo de caso se foram coerentes com a realidade do sistema. O modelo de qualidade, como discutido no primeiro artigo, não obteve um ajuste excelente com as medições para o reservatório da UHE Jurumirim, porém a falta de dados medidos em campo torna difícil a interpretação dos causadores das diferenças entre o modelo e o que foi observado em campo. Mesmo com as ressalvas e simplificações adotadas, o método é capaz de ajudar no entendimento do elevado número de incertezas dos fenômenos que regem um determinado sistema.

As principais contribuições apresentadas neste trabalho são:

- Desenvolvimento de um método para a determinação do tempo de aquecimento do GLM. Sendo que para o reservatório de Jurumirim, perfis constantes necessitam de tempo de aquecimento superior a 90 dias.
- Geração e aplicação de séries de sintéticas em reservatórios, criadas através de regressão linear (temperatura da água) e por modelos autoregressivos de primeira ordem (parâmetros de qualidade da água) para rios.
- Desenvolvimento de rotinas em linguagem python para a execução em massa do modelo GLM, sendo elas utilizadas para análises de sensibilidade, calibração e tempo de aquecimento do modelo.
- Criação de um método maleável e capaz de auxiliar na compreensão das incertezas e probabilidades de ocorrência de um determinado fenômeno - utilizando a combinação entre modelos computacionais, séries históricas e análise probabilística.
- Análise integrada das incertezas dentro da previsão de qualidade da água.
- Proposta de validação da matriz de transição, utilizando resultados modelados, dado a falta de observações de campo.
- Utilização e visualização de uma matriz de transição dentro de uma série temporal, com a finalidade de auxiliar em processos preditivos. Método esse que auxilia não na previsão em si, mas também na análise das incertezas e limitações que a natureza dos processos dentro do sistema impõem nos reservatórios.

Sugestões Futuras de Pesquisa e Desenvolvimento do Tema

- Remodelagem considerando interações do fitoplâncton e zooplâncton nos processos químicos do reservatório.
- Comparação de resultados utilizando modelos para reservatórios mais simplificados, tanto em escala temporal quanto espacial.
- Criação de uma matriz de transição utilizando um sistema de equações capazes de serem resolvidas analiticamente para representar a qualidade da água em um sistema.

REFERÊNCIAS

- AEMON. **Aquatic Ecosystem Modelling Network**. [S.l.: s.n.], 2020. Disponível em: <<https://sites.google.com/site/aquaticmodelling/home>>.
- AHMED, Ali Najah et al. Machine learning methods for better water quality prediction. **Journal of Hydrology**, Elsevier, v. 578, p. 124084, 2019.
- ANA. **Agência Nacional de Águas**. [S.l.: s.n.], 2019. Acessado em 02/2019. Disponível em: <<https://www.ana.gov.br/>>.
- AREFINIA, Ali et al. Reservoir water quality simulation with data mining models. **Environmental Monitoring and Assessment**, Springer, v. 192, n. 7, p. 1–13, 2020.
- ASSIS ESTEVES, Francisco de. **Fundamentos de limnologia**. [S.l.]: Interciência, 1998.
- BARZEGAR, Rahim et al. Multi-step water quality forecasting using a boosting ensemble multi-wavelet extreme learning machine model. **Stochastic environmental research and risk assessment**, Springer, v. 32, n. 3, p. 799–813, 2018.
- BERNARDO, Julio Werner Yoshioka. **Linking water quality issues with residence time and dimensionless numbers in reservoir**. 2018. Tese (Doutorado) – Universidade Federal do Paraná, <https://acervodigital.ufpr.br/handle/1884/58929>.
- BRUCE, Louise C et al. A multi-lake comparative analysis of the General Lake Model (GLM): Stress-testing across a global observatory network. **Environmental modelling & software**, Elsevier, v. 102, p. 274–291, 2018.
- BRUGGEMAN, Jorn; BOLDING, Karsten. A general framework for aquatic biogeochemical models. **Environmental modelling & software**, Elsevier, v. 61, p. 249–265, 2014.
- CALLAHAM, Jared L; MAEDA, Kazuki; BRUNTON, Steven L. Robust flow reconstruction from limited measurements via sparse representation. **Physical Review Fluids**, APS, v. 4, n. 10, p. 103907, 2019.
- CARVALHO, João Marcos. Generalização da Construção de Modelos para Reservatórios - Estudo de Caso UHE Jurumirim, 2020.
- CHAPIN, Thomas P. High-frequency, long-duration water sampling in acid mine drainage studies: A short review of current methods and recent advances in automated water samplers. **Applied Geochemistry**, Elsevier, v. 59, p. 118–124, 2015.
- CHEN, Siyu et al. Water quality prediction model of a water diversion project based on the improved artificial bee colony–backpropagation neural network. **Water**, Multidisciplinary Digital Publishing Institute, v. 10, n. 6, p. 806, 2018.

CHOU, Jui-Sheng; HO, Chia-Chun; HOANG, Ha-Son. Determining quality of water in reservoir using machine learning. **Ecological informatics**, Elsevier, v. 44, p. 57–75, 2018.

COLOMBO, Geovana Thaís. **Dinâmica térmica em rios e relações com variáveis meteorológicas**. 2019. Diss. (Mestrado) – Universidade Federal do Paraná, <https://acervodigital.ufpr.br/handle/1884/63819>.

DAMANIA, Richard et al. **Quality unknown: The invisible water crisis**. [S.l.]: The World Bank, 2019.

ELKIRAN, Gozen; NOURANI, Vahid; ABBA, SI. Multi-step ahead modelling of river water quality parameters using ensemble artificial intelligence-based approach. **Journal of Hydrology**, Elsevier, v. 577, p. 123962, 2019.

ERICHSON, N Benjamin et al. Shallow learning for fluid flow reconstruction with limited sensors and limited data. **arXiv preprint arXiv:1902.07358**, 2019.

FACCHI, A; GANDOLFI, C; WHELAN, MJ. A comparison of river water quality sampling methodologies under highly variable load conditions. **Chemosphere**, Elsevier, v. 66, n. 4, p. 746–756, 2007.

FENOCCHI, Andrea et al. Applicability of a one-dimensional coupled ecological-hydrodynamic numerical model to future projections in a very deep large lake (Lake Maggiore, Northern Italy/Southern Switzerland). **Ecological Modelling**, Elsevier, v. 392, p. 38–51, 2019.

FERREIRA, Danieli Mara. **Integrated analysis for modeling of flow and transport of contaminants in rivers**. 2019. Tese (Doutorado) – Universidade Federal do Paraná, <https://acervodigital.ufpr.br/handle/1884/61204>.

FERREIRA, Danieli Mara et al. Water quality modelling under unsteady state analysis: Strategies for planning and management. **Journal of environmental management**, Elsevier, v. 239, p. 150–158, 2019.

GLEON. **Global Lake Ecological Observatory Network**, disponível em <https://gleon.org/>. [S.l.: s.n.], 2020.

GOMIDE, Francisco Luis Sibut. Range and deficit analysis using Markov chains. **Hydrology papers (Colorado State University); no. 79**, Colorado State University Libraries, 1975.

GOMIDE, Francisco Luiz Sibut. **Sobre Reservatórios e Segurança Hídrica**. [S.l.], 2012.

HIDROWEB. **Sistema de informações Hidrológicas**, disponível em <http://www.snirh.gov.br/hidroweb/apresentacao>. [S.l.: s.n.], 2019. Acessado em 02/2019.

HIPSEY, Matthew R et al. A General Lake Model (GLM 3.0) for linking with high-frequency sensor data from the Global Lake Ecological Observatory Network (GLEON). **Geoscientific Model Development**, Copernicus GmbH, v. 12, n. 1, p. 473–523, 2019.

INMET. **Banco de Dados Meteorológicos para Ensino e Pesquisa**. [S.l.: s.n.], 2019. Acessado em 06/2019. Disponível em:
<<http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep>>.

JIA, Xiaowei et al. Physics guided RNNs for modeling dynamical systems: A case study in simulating lake temperature profiles. In: SIAM. PROCEEDINGS of the 2019 SIAM International Conference on Data Mining. [S.l.: s.n.], 2019. P. 558–566.

KOZAK, Caroline. **Water quality assessment and its effects on diffuse pollution considering a new water quality and quantity approach**. 2016. Diss. (Mestrado) – Universidade Federal do Paraná. Disponível em:
<<https://www.acervodigital.ufpr.br/handle/1884/43629>>.

LATOUCHE, Guy; RAMASWAMI, Vaidyanathan. **Introduction to matrix analytic methods in stochastic modeling**. [S.l.]: Siam, 1999. v. 5.

LUCKNER, Matheus Yago Antunes. **Análise da variação temporal do IQAR utilizando o modelo CEQUAL-W2: Proposta de um indicadores com alta resolução temporal**. [S.l.: s.n.], 2018.

MORAETIS, Daniel et al. High-frequency monitoring for the identification of hydrological and bio-geochemical processes in a Mediterranean river basin. **Journal of Hydrology**, Elsevier, v. 389, n. 1-2, p. 127–136, 2010.

MORAN, PAP. A probability theory of dams and storage systems. **Aust. Jour. App. Sci.**, v. 5, p. 116–124, 1954.

ORLOB, Gerald T. **Mathematical modeling of water quality: Streams, lakes and reservoirs**. [S.l.]: John Wiley & Sons, 1983. v. 12.

POMPÊO, Marcelo et al. Heterogeneidade espacial horizontal da qualidade da água no reservatório Rio Grande, Complexo Billings, São Paulo, Brasil. **POMPÊO, M.; MOSCHINI-CARLOS, V.; NISHIMURA, PH**, 2015.

PRATS, J; REYNAUD, N; DANIS, PA. Application of the General Lake Model (GLM) to a large set of French water bodies. In: IAHR. 5TH IAHR Europe Congress "New Challenges in Hydraulic Research and Engineering". [S.l.: s.n.], 2018. P. 337–338.

READ, Jordan S; HAMILTON, David P et al. Derivation of lake mixing and stratification indices from high-resolution lake buoy data. **Environmental Modelling & Software**, Elsevier, v. 26, n. 11, p. 1325–1336, 2011.

READ, Jordan S; WINSLOW, Luke A et al. Simulating 2368 temperate lakes reveals weak coherence in stratification phenology. **Ecological Modelling**, Elsevier, v. 291, p. 142–150, 2014.

SAHA, Suranjana; MOORTHY, Shrinivas; PAN, Hua-Lu et al. **NCEP Climate Forecast System Reanalysis (CFSR) 6-hourly Products, January 1979 to December 2010**. Boulder CO: Research Data Archive at the National Center for Atmospheric Research, Computational e Information Systems Laboratory, 2010. Disponível em: <<https://doi.org/10.5065/D69K487J>>.

SAHA, Suranjana; MOORTHY, Shrinivas; WU, Xingren et al. **NCEP Climate Forecast System Version 2 (CFSv2) 6-hourly Products**. Boulder CO: Research Data Archive at the National Center for Atmospheric Research, Computational e Information Systems Laboratory, 2011. Disponível em: <<https://doi.org/10.5065/D61C1TXF>>.

SAR. **Sistema de Acompanhamento de Reservatórios**. [S.l.: s.n.], 2019. Acessado em 04/2019. Disponível em: <<https://www.ana.gov.br/sar0/MedicaoSin>>.

TUNG, Tran Minh; YASEEN, Zaher Mundher et al. A survey on river water quality modelling using artificial intelligence models: 2000–2020. **Journal of Hydrology**, Elsevier, v. 585, p. 124670, 2020.